

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

**Matija Ostrunić**

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

Mentor:

Doc. dr. sc. Hrvoje Cajner

Student:

Matija Ostrunić

Zagreb, 2018

## **IZJAVA**

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Matija Ostrunić

---

## **ZAHVALA**

*Zahvaljujem svom mentoru doc. dr. sc. Hrvoju Cajneru na pruženoj stručnoj pomoći tijekom izrade ovog rada.*

*Također, zahvaljujem Društvu VODOVOD – OSIJEK d.o.o. na ukazanoj susretljivosti i pruženim informacijama bez kojih ovaj rad ne bi bio ostvariv.*

*Posebno zahvaljujem svojoj obitelji, roditeljima Željku i Gordani,  
bratu Iliji i djedu Franji  
na bezuvjetnoj podršci i razumijevanju tijekom mojeg obrazovanja.*

*Također, zahvaljujem svim svojim prijateljima i djevojci  
koji su moj neizostavan oslonac i podrška.*

*Matija Ostrunić*



SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za završne ispite studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo  
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

## ZAVRŠNI ZADATAK

Student: **Matija Ostrunić** Mat. br.: 0035199832  
Naslov rada na hrvatskom jeziku: **Primjena metode statističke kontrole u procesu tretiranja voda**  
Naslov rada na engleskom jeziku: **Application of SPC method in the water treatment process**

Opis zadatka:

Statistička kontrola procesa SPC (eng. *Statistical process control*) je metoda za praćenje i kontrolu kvalitete procesa. Metoda osigurava učinkovito praćenje kvalitete proizvoda ili usluga te omogućava pravovremenu korekciju i povećanje kvalitete smanjenjem nesukladnosti (škarta, otpada ...). SPC je moguće primijeniti na bilo koji proizvodni i uslužni proces gdje je prethodno utvrđena određena metrika (mjera kvalitete). U završnom radu potrebno je prikazati primjenu SPC-a u poduzeću koje se bavi pročišćavanjem voda. U radu je potrebno:

1. Snimiti proces te izraditi funkcijske mape i mapu toka vrijednosti za konkretni proces.
2. Detaljno opisati metriku kojom će biti izražena kvaliteta konačnog proizvoda.
3. Analizirati postojeću razinu kvalitete te u određenom vremenskom periodu pratiti istu.
4. Dati prijedlog poboljšanja s osvrtom na standardom propisanu razinu kvalitete.

Zadatak zadan:  
30. studenog 2017.

Rok predaje rada:  
**1. rok:** 23. veljače 2018.  
**2. rok (izvanredni):** 28. lipnja 2018.  
**3. rok:** 21. rujna 2018.

Predviđeni datumi obrane:  
**1. rok:** 26.2. - 2.3. 2018.  
**2. rok (izvanredni):** 2.7. 2018.  
**3. rok:** 24.9. - 28.9. 2018.

Zadatak zadao:

Dr. sc. Hrvoje Cajner, doc.

Predsjednik Povjerenstva:

Izv. prof. dr. sc. Branko Bauer

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	III
POPIS TABLICA.....	V
POPIS KRATICA .....	VI
SAŽETAK.....	VII
SUMMARY .....	VIII
1. UVOD.....	1
2. STATISTIČKA KONTROLA PROCESA .....	2
2.1. Varijacija procesa.....	3
2.2. Faze provođenja SPC metode .....	4
2.2.1. Početno uspostavljanje procesa – definiranje kontrolnih granica (SPC I).....	4
2.2.2. Redovita upotreba pri eksploatacijskim uvjetima procesa (SPC II) .....	5
2.3. Alati za prikaz analize.....	6
2.3.1. Kontrolni dijagrami.....	7
3. PROCES OBRADE (TRETIRANJA) VODA .....	8
3.1. Proces obrade otpadnih voda .....	9
3.1.1. Obrada tehnoloških (industrijskih) otpadnih voda.....	11
3.1.2. Obrada komunalnih (kućanskih) otpadnih voda .....	13
3.2. Proces obrade (kondicioniranja) vode za ljudsku potrošnju .....	14
4. KVALITETA VODE.....	16
4.1. Kvaliteta vode – pravni okvir.....	17
4.1.1. Direktiva 2000/60/EC – Okvirna direktiva o vodama .....	17
4.1.2. Zakon o vodama (NN 56/2013) .....	18
4.1.3. Pravilnik o vodi za ljudsku potrošnju (NN 125/2013).....	18
4.2. Parametri i metrika zdravstvene ispravnosti vode .....	19
5. ANALIZA TEHNOLOŠKOG PROCESA OBRADE VODE .....	23
5.1. VODOVOD – OSIJEK d.o.o. ....	23
5.2. Misija, vizija i ciljevi .....	25
5.3. Analiza tehnološkog procesa obrade vode za ljudsku potrošnju .....	26
5.3.1. Crpljenje sirove vode .....	28
5.3.2. Aeracija .....	29
5.3.3. Predoksidacija .....	29
5.3.4. Koagulacija .....	30

5.3.5. Flokulacija.....	31
5.3.6. Taloženje.....	31
5.3.7. Filtriranje i nitrifikacija.....	32
5.3.8. Dezinfekcija .....	32
5.3.9. Crpljenje vode u vodoopskrbnu mrežu .....	33
5.3.10. Nadzor procesa obrade i kontrola kvalitete vode.....	33
5.4. Funkcijska mapa toka vrijednosti .....	34
6. PRIMJENA STATISTIČKE KONTROLE PROCESA.....	36
6.1. Specifikacija podataka .....	36
6.2. Odabir kontrolnog dijagrama .....	37
6.3. Algoritam provedbe SPC metode .....	38
6.4. Amonijak.....	40
6.5. Željezo.....	47
6.6. Arsen .....	53
6.7. Usporedba rezultata.....	59
7. UNAPREĐENJE PROCESA OBRADE (TRETIRANJA) VODE.....	61
7.1. Proces uklanjanja arsena .....	61
7.2. Iskorištenje prerađene otpadne vode.....	61
7.3. Sustav dvostupanjske filtracije.....	62
7.4. Funkcijska mapa toka vrijednosti dvostupanjske filtracije .....	63
8. ZAKLJUČAK.....	64
LITERATURA.....	65
PRILOZI.....	66

## POPIS SLIKA

Slika 2.1	Preduvjeti za primjenu SPC metode.....	2
Slika 2.2	Uzroci varijacije u industrijskom (proizvodnom) procesu.....	4
Slika 2.3	Definiranje kontrolnih granica .....	5
Slika 2.4	Različiti prikazi analize [2] .....	6
Slika 2.5	Odabir odgovarajuće kontrolne karte [4] .....	7
Slika 3.1	Generiranje otpadnih voda u RH.....	9
Slika 3.2	Shema procesa obrade otpadnih voda [7].....	10
Slika 3.3	Proces obrade tehnoloških otpadnih voda [8] .....	11
Slika 3.4	Obrada i otpuštanje industrijskih otpadnih voda (2012. god.) .....	12
Slika 3.5	Udio stanovništva povezan na sustav za obradu komunalnih otpadnih voda [9]..	13
Slika 3.6	Shema postrojenja za kondicioniranje vode [10] .....	14
Slika 4.1	Ciljevi kontrole kvalitete vode .....	16
Slika 4.2	Parametri zdravstvene ispravnosti vode .....	19
Slika 5.1	Organizacija Poduzeća Vodovod – Osijek.....	23
Slika 5.2	Organizacija Društva VODOVOD – OSIJEK d.o.o. ....	24
Slika 5.3	Vodoopskrba mreža grada Osijeka i okolice [14] .....	26
Slika 5.4	Bunari na crpilištu Vinogradi [14] .....	28
Slika 5.5	Aeriranje sirove vode .....	29
Slika 5.6	Sustav za doziranje kalijeva permanganata.....	30
Slika 5.7	Sustav za doziranje željezovog klorida .....	30
Slika 5.8	Sustav za doziranje flokulanta PAA.....	31
Slika 5.9	Sustav za taloženje .....	31
Slika 5.10	Sustav za filtraciju vode .....	32
Slika 5.11	Sustav za crpljenje vode u vodoopskrbnu mrežu .....	33
Slika 5.12	SCADA sustav za nadzor i prikupljanje podataka .....	33
Slika 5.13	Aktivnosti VSM metode.....	34
Slika 5.14	Funkcijska mapa toka vrijednosti (VODOVOD – OSIJEK d.o.o.).....	35
Slika 6.1	Odabir kontrolnog dijagrama .....	37
Slika 6.2	Algoritam SPC metode.....	38
Slika 6.3	Numerička i grafička analiza (amonijak) .....	41
Slika 6.4	Stacionarnost procesa (amonijak) .....	42
Slika 6.5	Autokorelacija – ACF (amonijak).....	43
Slika 6.6	Autokorelacija – PACF (amonijak).....	43

Slika 6.7	Autokorelacija – ACF – ARMA (amonijak) .....	44
Slika 6.8	Autokorelacija – PACF – ARMA (amonijak) .....	44
Slika 6.9	X – MR kontrolni dijagram (amonijak) .....	45
Slika 6.10	Korigirani X – MR kontrolni dijagram (amonijak) .....	45
Slika 6.11	Sposobnost procesa (amonijak) .....	46
Slika 6.12	Numerička i grafička analiza (željezo) .....	48
Slika 6.13	Stacionarnost procesa (željezo) .....	49
Slika 6.14	Diferencijacija podataka (željezo) .....	49
Slika 6.15	Autokorelacija ACF/PACF (željezo) .....	50
Slika 6.16	Korigirana autokorelacija ACF/PACF (željezo) .....	50
Slika 6.17	X – MR kontrolni dijagram (željezo) .....	51
Slika 6.18	Korigirani X – MR kontrolni dijagram (željezo) .....	51
Slika 6.19	Sposobnost procesa (željezo) .....	52
Slika 6.20	Numerička i grafička analiza (arsen) .....	54
Slika 6.21	Stacionarnost procesa (arsen) .....	55
Slika 6.22	Diferencijacija podataka (arsen) .....	55
Slika 6.23	Autokorelacija ACF/PACF (arsen) .....	56
Slika 6.24	Korigirana autokorelacija ACF/PACF (arsen) .....	56
Slika 6.25	X – MR kontrolni dijagram (arsen) .....	57
Slika 6.26	Korigirani X – MR kontrolni dijagram (arsen) .....	57
Slika 6.27	Sposobnost procesa (arsen) .....	58
Slika 6.28	Broj podataka izvan kontrolnih granica .....	59
Slika 6.29	Demonstrirana sposobnost procesa .....	59
Slika 7.1	Funkcijska mapa toka vrijednosti dvostupanjske filtracije .....	63



## POPIS TABLICA

Tablica 3.1 Definicije korištenih pojmova uz kondicioniranje vode .....	15
Tablica 4.1 Kemijski parametri zdravstvene ispravnosti vode za ljudsku upotrebu [13] .....	20
Tablica 4.2 Indikatorski parametri (fizikalno – kemijski) [13] .....	21
Tablica 4.3 Mikrobiološki parametri zdravstvene ispravnosti vode za ljudsku upotrebu[13] .....	22
Tablica 4.4 Indikatorski parametri (radioaktivni) [13] .....	22
Tablica 5.1 Faze procesa obrade vode za ljudsku potrošnju (Vodovod – Osijek) .....	27
Tablica 6.1 Specifikacija podataka .....	36
Tablica 6.2 MDK vrijednosti odabranih elemenata .....	36
Tablica 6.3 Koncentracija amonijaka prije procesa obrade vode [mg/l] .....	40
Tablica 6.4 Koncentracija amonijaka nakon procesa obrade vode [mg/l] .....	40
Tablica 6.5 Koncentracija željeza prije procesa obrade vode [µg/l] .....	47
Tablica 6.6 Koncentracija željeza nakon procesa obrade vode [µg/l] .....	47
Tablica 6.7 Koncentracija arsena prije procesa obrade vode [µg/l] .....	53
Tablica 6.8 Koncentracija arsena nakon procesa obrade vode [µg/l] .....	53
Tablica 7.1 Usporedba tehnoloških postupaka [14] .....	62

## POPIS KRATICA

Kratika	Značenje kratice
ACF	Funkcija autokorelacije (eng. <i>Autocorrelation Function</i> )
ARIMA	eng. <i>Autocorrelation Integrated Moving Average</i>
MDK	Maksimalno dopuštena koncentracija
PAA	Poli – akril – amid (polielektrolit)
PACF	Funkcija parcijalne autokorelacije (eng. <i>Partial Autocorrelation Function</i> )
PLC	Programabilni logički kontroler (eng. <i>Programmable Logic Controller</i> )
SCADA	Sustav za nadzor i prikupljanje podataka (eng. <i>Supervisory Control And Data Acquisition</i> )
SPC	Statistička kontrola procesa (eng. <i>Statistical Process Control</i> )
VSM	Mapiranje toka vrijednosti (eng. <i>Value Stream Mapping</i> )

## SAŽETAK

Tema ovog rada je primjena metode statističke kontrole (eng. *Statistical Process Control* – SPC) u procesu tretiranja voda. SPC je metoda korištenja statistički utemeljenih alata i tehnika koje služe za upravljanje, kontrolu i poboljšanje procesa. Metoda osigurava učinkovito praćenje i omogućava pravovremenu korekciju te povećanje kvalitete samog procesa. Svaki proces mora se kontrolirati, a kontrola podrazumijeva bilježenje značajnih podataka.

U prvom dijelu rada ukratko su opisani fundamentalni pojmovi vezani uz SPC metodu te način njene primjene. Nakon upoznavanja s metodologijom SPC metode, opisani su osnovni procesi obrade voda s obzirom na njihovo porijeklo i krajnju primjenu. Proces obrade (tretiranja) voda najčešće obuhvaća niz postupaka kojima se uklanjaju ili smanjuju koncentracije određenih supstanci. U nastavku rada detaljno je opisana zakonski propisana metrika krajnjeg proizvoda – vode. U središnjem dijelu rada provedeno je snimanje i analiza konkretnog procesa obrade vode za ljudsku upotrebu te je izrađena funkcijska mapa toka vrijednosti. SPC metoda provedena je upravo na tom konkretnom procesu, a mjera kvalitete procesa definirana je uklonjenom koncentracijom praćenog parametra (praćeno je tri parametra: amonijak, željezo i arsen). Na kraju rada dan je prijedlog poboljšanja procesa s osvrtom na standardom propisanu razinu kvalitete te izneseni zaključci rada.

Ključne riječi: statistička kontrola procesa, SPC, tehnološki proces obrade voda, kvaliteta vode

## **SUMMARY**

The scope of the thesis aims at application of Statistical Process Control (SPC) in the water treatment process. The SPC is a method of using statically-based tools and techniques to manage, control and improve the process. The method ensures effective monitoring, enables timely correction and enhances the quality of the process itself. Every process has to be controlled, and control involves recording significant data.

The first part of the paper briefly describes the fundamental concepts related to the SPC method and the way it is applied. After getting acquainted with the methodology of the SPC method, basic water treatment processes have been described with regard to the water origin and end use. The water treatment process most often encompasses a series of procedures for removing or reducing concentrations of certain substances. In the continuation of the work, the legally prescribed metric of the end product (water) is described in detail. In the central part of the work, the recording and analysis of the real-case water treatment process was carried out and a functional flow chart was created. The SPC method was implemented precisely on this particular process, and the process quality measure was defined by the removed concentration of the monitored parameter (three parameters were monitored: ammonia, iron and arsenic). At the end of the work, there is a proposal for improvement of the water treatment process considering legally prescribed water quality level. Ultimately, conclusions were made and presented.

Key words: Statistical Process Control, SPC, water treatment process, water quality

## 1. UVOD

Voda kao ključni resurs i strateško dobro predmet je istraživanja mnogih struka, a njena kvaliteta ključan je čimbenik za život i funkcioniranje svakog pa i najmanjeg živog bića. Pojam kvalitete star je gotovo kao i ljudska civilizacija, a čovjek svojim kontinuiranim naporima želi dostići njezinu maksimalnu razinu u svim životnim sferama.

Značajan doprinos u postizanju zadovoljavajuće razine kvalitete vode za ljudsku upotrebu može se postići kroz proučavanje i analizu tehnološkog procesa obrade iste. Tehnološki proces obrade vode najčešće obuhvaća niz postupaka kojima se uklanjaju ili smanjuju koncentracije određenih supstanci na barem maksimalnu dopuštenu vrijednost propisanu zakonom (normom). Kako bi se postigla željena kvaliteta vode važno je poznavati ovaj proces te pratiti njegovu izvedbu tijekom vremena.

Statistička kontrola procesa (eng. *Statistical Process Control* – SPC) jedna je od metoda za kontrolu kvalitete procesa kojom se osigurava kontinuirano praćenje stabilnosti i sposobnosti istog. Za statističko praćenje procesa potrebno je odrediti elemente koji su relevantni - jednu ili više ključnih značajki koje treba pratiti, metriku procesa, mjerni postupak (mjerno sredstvo, mjesto i vrijeme mjerenja), veličinu i broj uzoraka te učestalost uzimanja uzoraka. Osnovni koncept statističke kontrole procesa temelji se na uspoređivanju podataka dobivenih iz procesa s definiranim granicama. Ključan korak je dobivene rezultate adekvatno interpretirati te na osnovu njih donijeti zaključke o samome procesu i budućim aktivnostima. Praćenjem tehnološkog procesa obrade voda SPC metodom moguće je pravovremeno reagirati i korigirati sam proces, a kao nužna posljedica toga je kontinuirana visoka kvaliteta obrađene vode koja zadovoljava sve uvjete propisane zakonom.

## 2. STATISTIČKA KONTROLA PROCESA

Cilj bilo koje analize podataka je razumijevanje, interpretiranje te na kraju donošenje odluka temeljem istih. Statistička kontrola procesa (eng. *Statistical Process Control* – SPC) je statistička metoda mjerenja i kontrole različitih industrijskih ili nekih drugih procesa s mjerljivim karakteristikama. Svaki promatrani proces po svojoj prirodi varira. Informacije o varijacijama su izuzetno bitne kako bi se svaki proces shvatio, pratio i unaprijedio. SPC metoda je alat pomoću kojeg se ove varijacije mogu uočiti, pratiti i držati u određenim, zadovoljavajućim granicama.

SPC je metoda korištenja statistički utemeljenih alata i tehnika koje služe za upravljanje, kontrolu i poboljšanje procesa. Glavni alat kojim se ova metoda služi je kontrolni dijagram.

Kontrolni dijagram karakterizira [1]:

- grafički prikaz karakteristika procesa
- prikaz karakteristika u ovisnosti o vremenu (vremenska skala)
- statistički određene kontrolne granice

Korištenjem kontrolnih dijagrama, korisniku se olakšava praćenje procesa i određivanje pravog vremena za poduzimanje određenih aktivnosti kako bi se promatrani proces održao u željenim uvjetima, a u konačnici unaprijedio.

Prije provođenja same metode jako je bitno razumjeti promatrani proces odnosno odrediti željene ciljeve procesa. Ključna karakteristika tijekom tog procesa je sistematičnost. Korake koje je potrebno poduzeti prije provođenja SPC metode prikazani su na [Slika 2.1].



Slika 2.1 Preduvjeti za primjenu SPC metode

Sve što se događa unutar bilo koje organizacije ili poduzeća nazivamo procesom koji [2]:

- posjeduje varijaciju
- može biti stabilan ili nestabilan
- ima određenu sposobnost
- zahtijeva adekvatno upravljanje i nadzor
- ima prostora za poboljšanje

Upravo se, zbog ovih karakteristika procesa, SPC metoda nameće kao odličan izbor pri praćenju i kontroli istih.

## 2.1. Varijacija procesa

Varijacija može biti definirana na puno načina, međutim tumačenje je uvijek isto. Varijacija predstavlja promjenu, odstupanje ili kolebanje. Svaki proces po svojoj prirodi varira. Kada ne bi postojalo varijacije, svijet kakav poznajemo ne bi postojao. Najjednostavniji primjer varijacije je čovjek kao ljudsko biće. Svi mi imamo karakteristike koje nas čine ljudskim bićem, međutim razlikujemo se u velikim razmjerima. Prebaci li se tematika na industrijske procese, najjednostavnije rečeno, varijacija predstavlja odstupanje konačnog proizvoda od željenih karakteristika koje kupac zahtijeva (dručkije rečeno, varijacijom industrijskog procesa uzrokovana je varijacija kvalitete proizvoda). Kako se SPC metoda temelji na principu varijacije, potrebno je objasniti određene pojmove za shvaćanje metode u potpunosti.

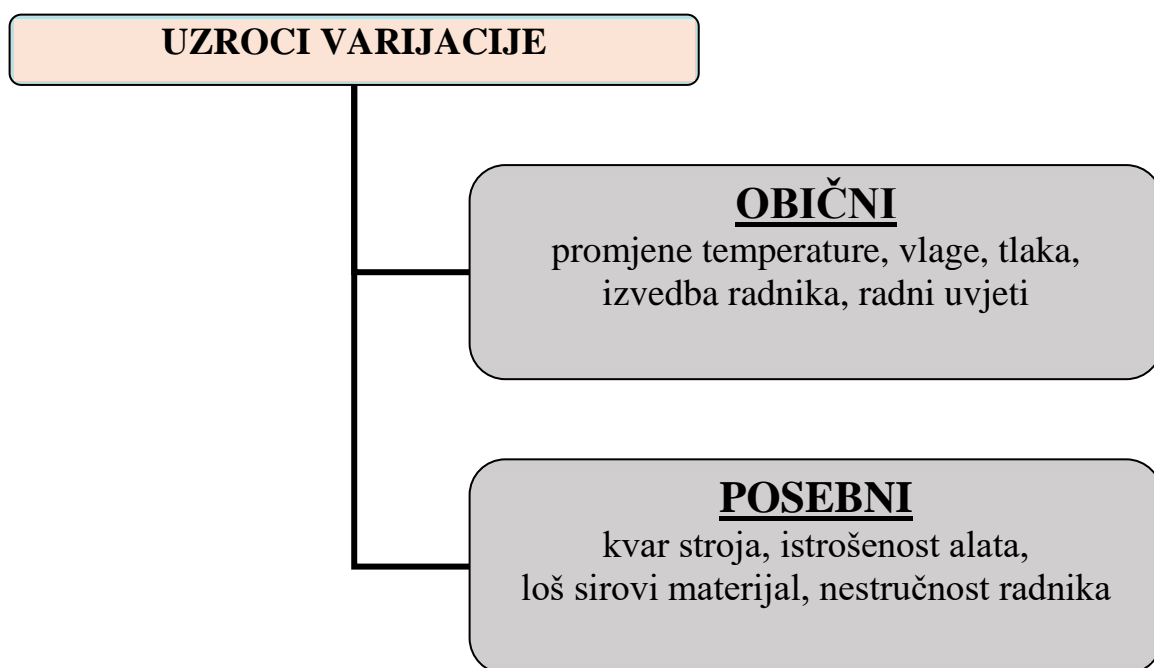
Prema uzroku varijacije razlikujemo:

- obične (slučajne) uzroke (eng. *Common Causes*)
- posebne (ne – slučajne) uzroke (eng. *Special Causes*)

Obični uzroci smatraju se sastavnim dijelom procesa i ne mogu se promijeniti bez promijene samog procesa. U ovakvim slučajevima, kada postoje samo obični tj. slučajni uzroci varijacije procesa, proces se smatra stabilnim ili jednostavno pod kontrolom (eng. *In-Control*).

S druge strane, ukoliko postoje posebni (ne – slučajni) uzroci varijabilnosti procesa, takav proces smatra se nestabilnim ili van kontrole (eng. *Out-Of-Control*).

Glavni zadatak SPC metode je identificirati i razlikovati obične od posebni uzroka varijacije procesa. Na [Slika 2.2] prikazani su neki ovih uzroka na primjeru klasičnog industrijskog (proizvodnog) procesa.



Slika 2.2 Uzroci varijacije u industrijskom (proizvodnom) procesu

## 2.2. Faze provođenja SPC metode

SPC metoda najčešće se dijeli u dvije faze [3]:

- 1.) početno uspostavljanje procesa – definiranje kontrolnih granica (SPC I)
- 2.) redovita upotreba pri eksploatacijskim uvjetima procesa (SPC II)


### 2.2.1. Početno uspostavljanje procesa – definiranje kontrolnih granica (SPC I)

U ovoj fazi pokušava se pravilno uspostaviti proces tako da on bude stabilan. Zbog činjenice da se prilikom ovog koraka ne zna puno o samom procesu, na početku ove faze, uključene su različite statističke metode koje imaju eksperimentalnu ulogu. Prvo što se proučava je povezanost između kvalitete, gotovih, već izrađenih proizvoda (eng. *Outputs*) i ulaznih procesnih parametara (eng. *Inputs*).

Nakon što je uočena određena korelacija između navedenih elemenata, regulirajući ulazni parametri postavljaju se na specifične vrijednosti tako da bi se „ugrubo“ zadovoljili projektirani zahtjevi kvalitete željenog proizvoda (ili usluge). U ovako stvorenim uvjetima počinju se prikupljati podaci potrebni za provođenje SPC metode koja se vrši prije navedenim kontrolnim dijagramima. Statističkim metodama definiraju se kontrolne granice kontrolnih dijagrama.



Ukoliko se uoči odstupanje promatranih vrijednosti od definiranih kontrolnih granica, potrebno je otkriti posebne uzroke varijacije. Nakon uklanjanja posebnih uzroka varijacije, definiraju se nove kontrolne granice. Ovaj korak kontrole i podešavanja najčešće se izvodi nekoliko puta [Slika 2.3]. Napokon, kada se uklone svi posebni uzroci varijacije procesa, postavljaju se konačne kontrolne granice koje će definirati stabilnost procesa u budućim razmatranjima.



**Slika 2.3 Definiranje kontrolnih granica**

### **2.2.2. Redovita upotreba pri eksploatacijskim uvjetima procesa (SPC II)**

Za početak druge faze SPC metode svi procesi moraju biti pod kontrolom i moraju imati definirane kontrolne granice. Glavni cilj ove faze SPC metode je pratiti proces u njegovim radnim uvjetima te osigurati njegovu stabilnost. Ukoliko se uoči signal koji javlja prekomjernu varijaciju procesa tj. pojavu posebnih uzroka varijacije, potrebno je što prije reagirati i ukloniti posebne uzročnike.

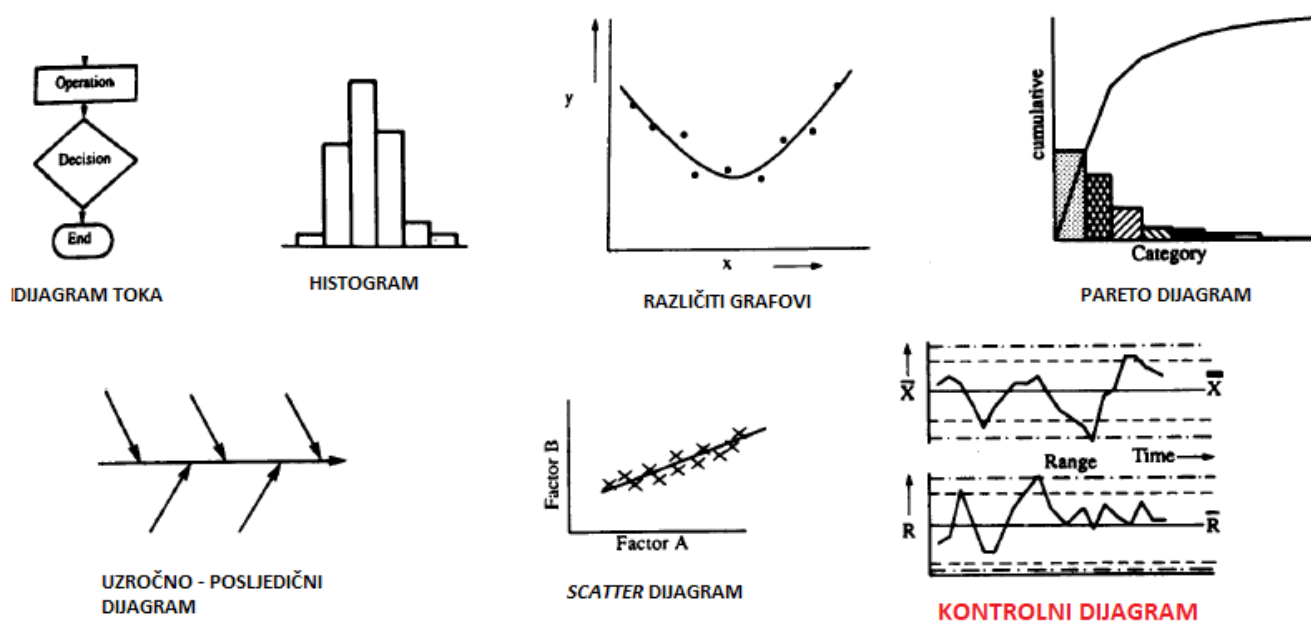
U ovu fazu također je uključen postupak mjerenja i praćenja sposobnosti promatranog procesa jer nema smisla govoriti o sposobnosti procesa ukoliko on nije pod kontrolom (stabilan). Također, bitno je naglasiti da proces koji nije u kontrolnim granicama ne proizvodni nužno niskokvalitetne ili loše proizvode (van granica specifikacije kupca), već je kod njega prisutna značajna varijacija zbog koje konačni proizvodi imaju različite karakteristike!

### 2.3. Alati za prikaz analize

Pri korištenju statističkih metoda na osnovu kojih se donose važne odluke, bitan je način prezentacije (vizualizacije) istih. Alati za prikaz podataka pomoću SPC metode su [2]:

- dijagram toka procesa
- histogrami
- različiti grafovi
- Pareto dijagram
- uzročno posljedični dijagram (eng. *Cause and Effect Diagram*)
- dijagram rasipanja (eng. *Scatter Plot*)
- **Kontrolni dijagrami**

Dakako, najčešće su korišteni kontrolni dijagrami, međutim ostali alati se mogu također koristiti za prikaz unutar SPC metode. Na [Slika 2.4] prikazani su izgledi ovih alata.



Slika 2.4 Različiti prikazi analize [2]

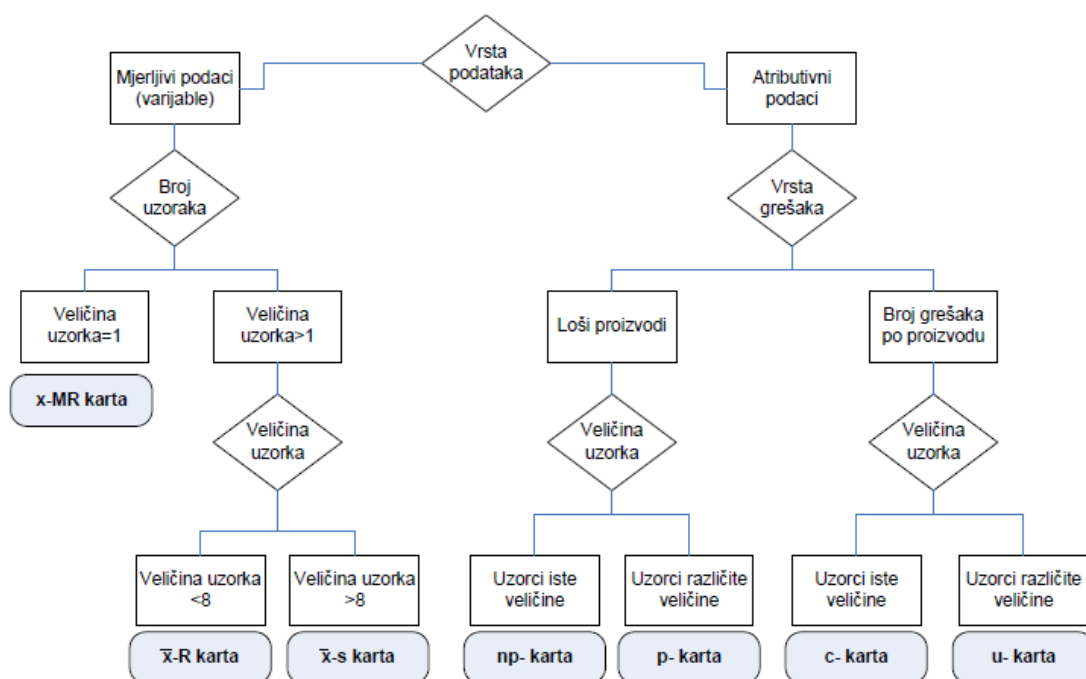
### 2.3.1. Kontrolni dijagrami

Generalno, podaci (varijable) se mogu kategorizirati u dvije grupe, a to su kontinuirane (mjerljive karakteristike) i diskretne (atributne karakteristike) varijable. Postupci statističke kontrole tj. SPC metode su različiti za različite varijable. Ono što im je zajedničko kod ove metode je pretpostavka normalne distribucije podataka. Kontrolni dijagrami mogu se koristiti za praćenje i jednih i drugih varijabli.

Kontrolni dijagrami se mogu podijeliti na sljedeće:

- Kontrolni dijagrami mjerljivih karakteristika
  - $\bar{X}$  – R dijagram
  - $\bar{X}$  – S dijagram
  - X – MR dijagram
- Kontrolni dijagrami atributivnih karakteristika
  - p dijagram
  - np dijagram
  - c dijagram
  - u dijagram

Na [Slika 2.5] prikazan je algoritam za odabiranje odgovarajućeg kontrolnog dijagrama.



Slika 2.5 Odabir odgovarajuće kontrolne karte [4]

### 3. PROCES OBRADE (TRETIRANJA) VODA

Urbanistički razvoj, mnogobrojne industrije, povećanje stanovništva i neadekvatno gospodarenje otpadnom samo su neki od faktora koji uvjetuju zagađenje čovjekove okoline, a uzročno – posljedično i zagađenje voda. Zagađenje voda ubraja se među najznačajnija zagađenja kojima se ugrožava čovjekova životna sredina. Kako je voda ključni resurs za živi svijet, potrebno je provoditi određene procese obrade iste, kojima bi se postiglo stanje ispravnosti i zadovoljavajuće kvalitete za specifičnu primjenu.

Proces obrade (tretiranja) voda najčešće obuhvaća niz postupaka kojima se uklanjaju ili smanjuju koncentracije određenih supstanci. Također, svaki proces koji za cilj ima poboljšavanje kvalitete vode za krajnju upotrebu (voda za industrijska postrojenja, voda za domaćinstva, voda za povrat u okoliš...) može se identificirati kao proces tretiranja voda. Može se tvrditi da je klasifikacija obrade voda prema njenoj namjeni najčešća te mnogi autori koriste upravo tu podjelu.

Tako je prema [5] ona podijeljena na:

- obrada otpadnih voda
- obrada vode za ljudsku upotrebu (pitka voda)
- obrada vode za razne industrijske namjene (napojne, rashladne, protupožarne...)

Proces obrade vode može se razlikovati s obzirom na:

- lokaciju sirove (prirodne) vode koja se crpi (podzemna, površinska)
- tehnologiju postrojenja
- vrstu vode koja se obrađuje
- konačnu upotrebu (namjenu) obrađene vode (ljudska upotreba, vraćanje u okoliš)

Iako se navedeni procesi djelomično razlikuju, osnovni principi obrade gotovo su identični. Slijednim prolaskom sirove vode kroz nekoliko etapa integriranog postrojenja te primjenom određene tehnologije teži se postizanju samo jednog, a to je željena razina kvalitete vode.


### 3.1. Proces obrade otpadnih voda

Sve vode koje su iskorištene za nekakvu namjenu, bilo da je riječ o kućanskim ili industrijskim vodama, potrebno je prikupiti kao otpadnu vodu te ju na prikladan način obraditi i odvesti u prijemnike bez štetnih posljedica za okoliš i bez narušavanja prirodnog kružnog toka vode (hidrološki ciklus). Prijemnici mogu biti prirodne vode poput rijeka, jezera ili mora. Također, u određenim slučajevima veliki dio otpadne vode moguće je, uz određenu obradu, ponovno koristiti za prvobitne ili neke druge procese.

Najčešća je podjela otpadnih voda prema podrijetlu na [6]:

- komunalne (kućanske) otpadne vode
- industrijske otpadne vode

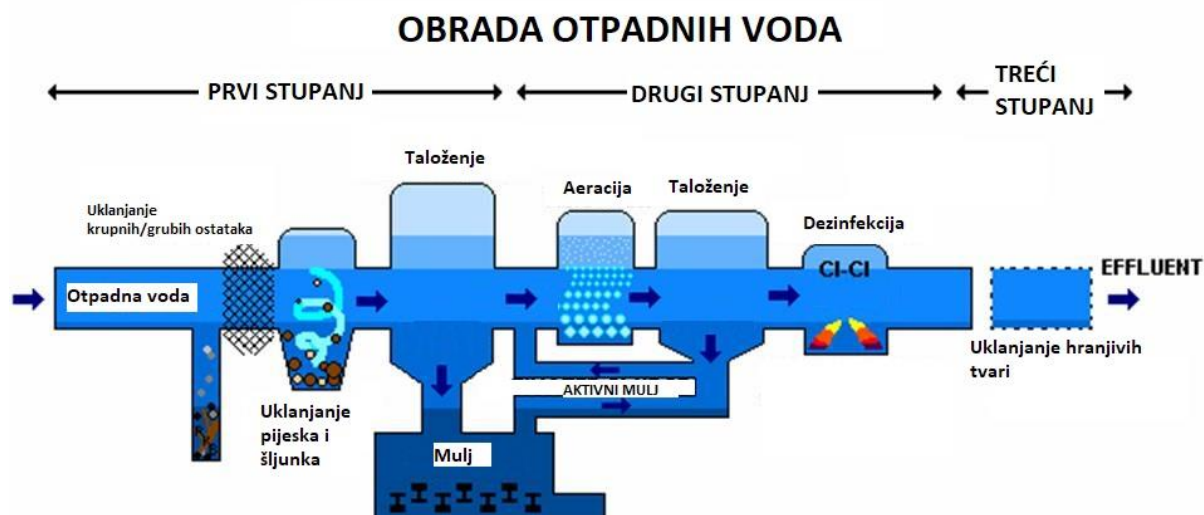
Fizikalni, kemijski i biokemijski sastav otpadnih voda ovisan je o mnogobrojnim faktorima kao što su topografski i geografski uvjeti, različiti industrijski efluenti, a u današnje vrijeme sve češći i tzv. „moderni“ utjecajni faktori su nusprodukti farmaceutske industrije. Bitno je naglasiti da zbog različitog sastava otpadnih voda one utječu na izvedbu samog sustava za obradu, a isto tako i na sustav kanala kojima se prikupljaju i obrađuju.



**Slika 3.1 Generiranje otpadnih voda u RH**

Dijagram na [Slika 3.1] prikazuje generiranje otpadnih voda u Republici Hrvatskoj za razdoblje od 2008. do 2013. godine. Lako se može zaključiti da se generira velika količina otpadnih voda te kako bi se spriječilo njihovo otpuštanje u okoliš, a samim time uzrokovalo zagađenje, potrebno je istu provesti kroz proces obrade otpadnih voda.

Otpadna se voda, bez obzira na njeno porijeklo, obrađuje u jednom, dva ili tri stupnja. Ti stupnjevi obuhvaćaju postupke mehaničke obrade, biološke procese, postupke uklanjanja masti i ulja te kemijske postupke. Logičan je zaključak da prolaskom otpadne vode kroz više stupnjeva obrade ona postaje pogodnija za svoj prirodni recipijent ili u nekim slučajevima za ponovnu upotrebu.



Slika 3.2 Shema procesa obrade otpadnih voda [7]

Na [Slika 3.2] prikazani su prije navedeni stupnjevi obrade otpadnih voda. Ovisno o vrsti otpadne vode, njenim karakteristikama i propisanim zakonom, obrada se može vršiti u nekom od prikazanih stupnjeva. Naravno, u današnje doba teži se obradi u tri stupnja kako bi se poboljšalo gospodarenje vodnim resursima, a isto tako manje utjecalo na okoliš.


Prvi stupanj karakteriziraju mehanički postupci za uklanjanje grube suspendirane tvari. Za drugi stupanj karakteristični su fizikalno – kemijski i biološki postupci kojima se umanje koncentracija ostalih suspendiranih tvari na dopuštenu razinu. Zadnji, odnosno treći stupanj također karakteriziraju fizikalno – kemijski i biološki postupci, ali ovoga puta korišteni za uklanjanje hranjivih tvari.

### 3.1.1. Obrada tehnoloških (industrijskih) otpadnih voda

Sastav tehnoloških otpadnih voda usko je povezan s granom industrije iz kojih otpadne vode nastaju kao nužan produkt proizvodnog procesa (farmaceutska industrija, tekstilna industrija, metaloprerađivačka industrija, prehrambena industrija...) ili je ovisan o tehnološkom procesu pretvorbe energije uz koji su otpadne vode vezane (termoelektrane, nuklearne elektrane, hidroelektrane).


Najčešći parametri koji se prate u industrijskim otpadnim vodama su [6]:

- mikroorganizmi
- pokazatelji organskih tvari
- pojedinačne tvari koje su posljedica tehnološkog procesa (npr. teški metali, ulja, masti, radioaktivne tvari itd.)



Slika 3.3 Proces obrade tehnoloških otpadnih voda [8]

Na [Slika 3.3] prikazan je shema klasičnog proces obrade tehnoloških otpadnih voda. On uključuje doziranje određenih elemenata kao što su željezov (III) klorid, klor i amonijak, različite spremnike (aerobni, anaerobni, anoksični, stabilizacijski), taložnike te filtere (najčešće gravitacijski). Nakon ovakve obrade, efluent (obrađena voda) spremna je za ispuštanje u okoliš, a u nekim slučajevima i za ponovno upotrebu.



**Slika 3.4 Obrada i otpuštanje industrijskih otpadnih voda (2012. god.)**

Na dijagramu sa [Slika 3.4] prikazana je usporedba između nekoliko država u ovisnosti o otpuštanju obrađenih i neobrađenih industrijskih (tehnoloških) otpadnih voda. Može se zaključiti da je problem otpuštanja neobrađenih industrijskih voda još uvijek veliki te uzrokuje neželjeno zagađenje okoliša koji nas okružuje. Prema dijagramu se može uvidjeti da je Republika Hrvatska na samom začelju ovog poretka te da su nužni određeni koraci kako bi se smanjio, a u konačnici uklonio, štetan utjecaj neobrađenih otpadnih voda na živi svijet.




### 3.1.2. Obrada komunalnih (kućanskih) otpadnih voda

Komunalne otpadne vode nastaju u urbanističkim zonama. Radi se o vodama koje su iskorištene u neproizvodnim djelatnostima kao što je kućanstvo, zdravstvo ili školstvo. Slično kao i kod tehnoloških otpadnih voda, komunalne otpadne vode imaju sebi karakterističan sastav. One najčešće sadrže biorazgradive tvari (proteini, lipidi), suspendirane tvari te veliki broj mikroorganizama.

Stoga su najvažniji pokazatelji sustava kućanskih otpadnih voda [6]:

- sadržaj organskih tvari
- količina suspendiranih tvari
- ukupni dušik, kalij, fosfor
- broj patogenih organizama

Sustavi koji prikupljaju, obrađuju i ispuštaju ovakvu vodu nazivaju se kanalizacijskim sustavima. Oni mogu biti centralizirani ili decentralizirani ovisno o lokalnim uvjetima gdje se nalazi. Centralizirani sustav nudi primjenu zahtjevnijih tehnologija, dok decentralizirani sustav nudi fleksibilnost i jednostavnost.



**Slika 3.5 Udio stanovništva povezan na sustav za obradu komunalnih otpadnih voda [9]**

Na [Slika 3.5] prikazana je karta svijeta te su naznačeni udjeli stanovništva, po pojedinim državama, čija su kućanstva povezana na sustav za obradu komunalnih otpadnih voda. Hrvatska pripada području od 60% do 80% .


### 3.2. Proces obrade (kondicioniranja) vode za ljudsku potrošnju

Iako su svi procesi obrade voda bitni, može se reći da je proces obrade (kondicioniranja) vode za piće najvažniji. Tako obrađena voda ima direktan utjecaj na čovjeka, a predstavlja najosnovniju prehrambenu tvorevinu koja je od izuzetnog fiziološkog i higijenskog značaja. Kondicioniranje vode je proces kojim se postiže zdravstvena ispravnost vode za ljudsku upotrebu, odnosno kojim se zadovoljavaju svi uvjeti propisani zakonom.

Priroda koja nas okružuje nije ujednačena pa tako svaki izvor vode (vodozahvatno mjesto) ima svoje specifičnosti, a postupak kondicioniranja te vode mora se prilagoditi svakom konkretnom slučaju. Priprema vode za piće vrši se primjenom različitih slijednih postupaka i operacija s ciljem postizanja propisane razine kvalitete. Bitno je naglasiti da se procesi kondicioniranja vode za piće temelje se na fizikalnim, kemijskim i biološkim djelovanjima.

Primarni zadaci koji se trebaju izvršiti ovim postupkom su [10]:

- uklanjanje raspršenih (suspendiranih) tvari tj. smanjenje mutnoće
- uklanjanje tvari koje uzrokuju obojanost vode
- uklanjanje masti i ulja (flotacija)
- uklanjanje otopljenih plinova (degazacija) i ukupnih soli (desalinizacija)
- uklanjanje organske tvari
- promijeniti tvrdoću vode
- uništavanje patogenih mikroorganizama (dezinfekcija)



Slika 3.6 Shema postrojenja za kondicioniranje vode [10]

Na [Slika 3.6] prikazana je shema najčešćeg oblika postrojenja za kondicioniranje vode. Proces je podijeljen u nekoliko faza:

- 1.) otapanje i doziranje koagulanta
- 2.) miješanje koagulanta i tretirane vode
- 3.) flokulacija
- 4.) taloženje (sedimentacija)
- 5.) filtriranje
- 6.) dezinfekcija

Uz ove navedene faze, često se koriste i dopunske aktivnosti kao što su aeracija, flotacija, predoksidacija i oksidacija te omekšavanje.

**Tablica 3.1 Definicije korištenih pojmova uz kondicioniranje vode**

<b>KOAGULACIJA</b>	Proces neutralizacije, odnosno destabilizacije negativno nabijenih čestica – koloida u sirovoj vodi.
<b>KOAGULANTI</b>	Kemijski spojevi (reagensi) koji se dodaje pri procesu koagulacije. Primjeri: željezov klorid ( $\text{FeCl}_3$ ), alaun, željezov sulfat ( $\text{Fe}_2(\text{SO}_4)_3$ )
<b>FLOKULACIJA</b>	Proces aglomeracije (spajanja) destabiliziranih čestica – koloida.
<b>FLOKULANTI</b>	Kemijski spoj (reagens) koji se dodaje pri procesu flokulacije. Primjer: PAA (poli-akril-amid), Superfloc, Purifloc
<b>TALOŽENJE</b>	Proces uklanjanja zrnatih čestica pod utjecajem gravitacijske sile.
<b>FILTRACIJA</b>	Proces protjecanja vode kroz poroznu sredinu odnosno filtarski materijal (najčešće kvarcni pijesak i antracit).
<b>DEZINFEKCIJA</b>	Završno uklanjanje mikroorganizama primjenom kemijskih spojeva (reagensa).
<b>AERACIJA</b>	Proces dovođenja atmosferskog zraka u kontakt s vodom, odnosno obogaćivanje vode kisikom.
<b>FLOTACIJA</b>	Proces uklanjanja masti i ulja.

## 4. KVALITETA VODE

U okolišu koji nas okružuje ne postoji idealno čista voda, već ju je potrebno obrađivati, ali isto tako i pratiti određene parametre kvalitete koji ukazuju na uspješnost samog procesa obrade. Jednako je važno pratiti kvalitetu prirodne (sirove) i obrađene vode. Dakako, gledajući iz ljudske perspektive, najbitnija je kvaliteta vode koja je namijenjena za ljudsku potrošnju. To je sva voda koja je namijenjena za piće, održavanje higijene, kuhanje ili neku drugu kućansku potrebu, neovisno o njenom podrijetlu (javna vodoopskrba, flaširana voda i sl.). Neobrađena ili loše tretirana voda predstavlja zdravstveni rizik za čovjeka te je upravo zbog toga bitno provoditi kontrolu kvalitete vode. Cilj kontrole kvalitete je provjeriti i utvrditi njenu zdravstvenu ispravnost za željenu namjenu.

Kontrolom kvalitete najčešće se utvrđuju sljedeće značajke vode:

- fizikalne značajke
- kemijske značajke
- mikrobiološke značajke
- radioaktivne značajke

Na [Slika 4.1] prikazani su neki od glavnih ciljeva provođenja kontrole kvalitete.



**Slika 4.1** Ciljevi kontrole kvalitete vode

#### 4.1. Kvaliteta vode – pravni okvir

Kako bi se omogućio pravilan proces kontrole kvalitete vode, potrebno je odrediti metriku samog procesa. Zbog izuzetnog značaja zdravstvene ispravnosti vode namijenjene za opskrbu i upotrebu stanovništva, svaka država propisuje zakone kojima je definirana metrika kvalitete.

U ovom poglavlju spomenut će se sljedeći propisani zakoni:

Europska unija	Republika Hrvatska
➤ Direktiva 2000/60/EC – Okvirna direktiva o vodama (eng. <i>Water Framework Directive</i> )	➤ Zakon o vodama (NN 56/2013) ➤ Pravilnik o parametrima sukladnosti i metodama analize vode za ljudsku potrošnju (NN 125/2013)

##### 4.1.1. Direktiva 2000/60/EC – Okvirna direktiva o vodama

Direktiva 2000/60/EC predstavlja Okvirnu direktivu o vodama propisanu od strane Europske komisije tj. Europske unije. Ona se bavi definiranjem ekološko – kemijskog stanja prirodnih voda.

Ekološko stanje prirodnih voda utvrđuje se pomoću kriterija [11]:

- biološki elementi kvalitete
- hidromorfološki elementi kvalitete
- kemijski i fizikalno – kemijski elementi kvalitete
- specifična zagađivala

Kemijsko stanje prirodni voda utvrđuje se sukladno sljedećim direktivama (nisu navedene sve):

- Direktiva o otpuštanju žive
- Direktiva o otpuštanju opasnih tvari
- Direktiva o otpuštanju kadmija

Ciljevi Direktive 2000/60/EC su:

- sustavno motrenje kvalitete vode
- eliminacija opasnih tvari
- očuvanje i unapređenje ekološko – kemijskog stanja voda

#### **4.1.2. Zakon o vodama (NN 56/2013)**

U Republici Hrvatskoj zdravstvena ispravnost, odnosno kvaliteta vode regulirana je Zakonom o vodama (NN 56/2013).

Ovaj zakon propisuje ciljeve upravljanje vodama [12]:

- osiguranje dovoljnih količina kvalitetne pitke vode za vodoopskrbu stanovništva
- osiguranje potrebnih količina vode odgovarajuće kvalitete za različite gospodarske i osobne potrebe
- postizanje i očuvanje dobrog stanja voda radi zaštite života i zdravlja ljudi, zaštite njihove imovine, zaštite vodnih i o vodi ovisnih ekosustava

Kako je kontrola kvalitete vode od izuzetne važnosti, ovaj zakon definira i proces praćenja stanja voda (monitoring). Monitoring stanja voda usko je povezan s kontrolom kvalitete vode.

Propisani ciljevi monitoringa ovog zakona su [12]:

- utvrđivanje dugoročnih promjena
- utvrđivanje ekološkog potencijala vode
- utvrđivanje ekološkog i kemijskog stanja vode
- količinsko i kemijsko stanje podzemnih voda
- kreiranje izvješća o provedenom monitoringu


#### **4.1.3. Pravilnik o vodi za ljudsku potrošnju (NN 125/2013)**

Punim nazivom – Pravilnik o parametrima sukladnosti i metodama analize vode za ljudsku potrošnju (NN 125/2013) propisuje sljedeće [13]:

- parametre zdravstvene ispravnosti i indikatorske parametre vode za ljudsku potrošnju (mikrobiološki, kemijski i radioaktivni)
- učestalost uzimanja uzoraka vode za ljudsku upotrebu za analizu (monitoring)
- parametre, vrste i opseg analize uzoraka vode za ljudsku potrošnju
- metode laboratorijskog ispitivanja zdravstvene ispravnosti vode za ljudsku potrošnju

#### 4.2. Parametri i metrika zdravstvene ispravnosti vode

Prema prethodno navedenom Pravilniku o parametrima sukladnosti i metodama analize vode za ljudsku potrošnju (NN 125/2013), ključni parametri kojima se može odrediti zdravstvena ispravnost vode za ljudsku potrošnju mogu se podijeliti u tri skupine kako je prikazano na [Slika 4.2].



**Slika 4.2 Parametri zdravstvene ispravnosti vode**

Kako bi se voda za ljudsku potrošnju mogla kontrolirati, potrebno je odrediti dozvoljene vrijednosti tj. maksimalno dopuštene koncentracije (MDK) prije navedenih parametara. MDK vrijednosti također su propisane Pravilnikom (NN 125/2013).

Ukoliko određeni parametar prekoračuje maksimalno dopuštenu koncentraciju propisanu zakonom, potrebno je procijeniti utjecaj promatranog parametra koji odstupa od tražene vrijednosti na zdravlje čovjeka te poduzeti potrebne mjere i uočeni parametar dovesti pod kontrolu tj. uskladiti njegovu razinu s propisanom vrijednošću. U suprotnom, krajnji će korisnik neadekvatno obrađene vode imati povećani zdravstveni rizik.

U nastavku će biti prikazani parametri s njihovom metrikom (mjerna jedinica) i MDK vrijednošću koji su propisani zakonom.

**Tablica 4.1 Kemijski parametri zdravstvene ispravnosti vode za ljudsku upotrebu [13]**

Pokazatelj	Jedinica	MDK
Akrlamid	µg/l	0,1
Antimon	µg/l	5
Arsen*	µg/l	50
Benzen	µg/l	1
Benzo(a)pyrene	µg/l	0,01
Bor	mg/l	1
Bromati	µg/l	10
Kadmij	µg/l	5
Krom	µg/l	50
Bakar	mg/l	2
Cijanidi	µg/l	50
1,2-dikloroetan	µg/l	3
Epiklorhidrin	µg/l	0,1
Fluoridi	mg/l	1,5
Olovo	µg/l	10
Živa	µg/l	1
Nikal	µg/l	20
Nitrati	mg/l	50
Nitriti	mg/l	0,5
Pesticidi ukupni	µg/l	0,5
PAH	µg/l	0,1
Selen	µg/l	10
Suma tetrakloreten i trikloreten	µg/l	10
THM – ukupni	µg/l	100
Vinil klorid	µg/l	0,5
Klorit	µg/l	400
Otopljeni Ozon	µg/l	50



**Tablica 4.2 Indikatorski parametri (fizikalno – kemijski) [13]**

<b>Pokazatelj</b>	<b>Jedinice</b>	<b>MDK</b>
Aluminij	µg/l	200
Amonijak	mg/l	0,5
Barij	µg/l	700
Boja	mg/PtCo skale	20
Cink	µg/l	3000
Detergenti	µg/l	200
Fosfati	µg/l	300
Kalij	mg/l	12
Kloridi	mg/l	250
Koncentracija vodikovih iona	pH jedinica	6,5-9,5
Mangan	µg/l	50
Ugljikovodici	µg/l	50
Miris		bez
Mutnoća	NTU	4
Natrij	mg/l	200
Okus		bez
Silikati	mg/l	50
Slobodni klor	mg/l	0,5
Srebro	µg/l	10
Sulfati	mg/l	250
Temperatura	°C	25
TOC	mg/l	Bez značajnih promjena
Ukupne suspenzije	mg/l	10
Utrošak KMnO4	O2 mg/l	5
Vanadij	µg/l	5
Vodikov sulfid		bez
Vodljivost	µS/cm /20 °C	2500
Željezo	µg/l	200

**Tablica 4.3 Mikrobiološki parametri zdravstvene ispravnosti vode za ljudsku upotrebu[13]**

Pokazatelj	Jedinice	MDK
Escherichia coli	broj/100 ml	0
Enterokoki	broj/100 ml	0
Clostridium perfringens	broj/100 ml	0
Pseudomonas aeruginosa	broj/100 ml	0
Enterovirusi	broj/5000 ml	0

**Tablica 4.4 Indikatorski parametri (radioaktivni) [13]**

Pokazatelj	Jedinice	MDK
Tricij	Bq/l	100
Radon	Bq/l	100

**Napomene:**

\* Po novom EU pravilniku MDK arsena iznosi 10 µg/l.


Žutom bojom označeni su parametri koji će se razmatrati prilikom primjene SPC metode.

## 5. ANALIZA TEHNOLOŠKOG PROCESA OBRADE VODE

Početak vodoopskrbe u gradu Osijeku veže se uz osamdesete godine 19. stoljeća kada je grad dobio prvu crpnu stanicu na rijeci Dravi. Sredinom 20. stoljeća izgrađen je pogon za proizvodnju vode na lokalitetu Nebo pustara te nova crpna stanica na Pampasu. Nedugo zatim, kvalitete dravske vode drastično se pogoršala pod utjecajem raznih faktora, a kao glavni može se istaknuti industrijski razvoj. Promjena je bila toliko negativna da se postojeća tehnologija proizvodnje pitke vode nikako nije mogla prilagoditi novonastalim uvjetima. Napokon, osamdesetih godina prošlog stoljeća, Osijek dobiva novi pogon za proizvodnju i distribuciju vode koji kao izvor sirove vode koristi vodu iz osamnaest zdenaca (bunara) s crpilišta Vinogradi. Kontinuiranim ulaganjima, stalnom modernizacijom te marljivom ophodnjom, navedeni sustav koristi se i dan danas. Analiza tehnološkog procesa obrade vode za ljudsku upotrebu izvršit će se na ovom sustavu.

### 5.1. VODOVOD – OSIJEK d.o.o.


Krajem 20. stoljeća Radna organizacija Vodovod-Osijek temeljem novih zakonskih propisa mijenja naziv u Poduzeće Vodovod-Osijek u čijem se sastavu nalaze osnovne organizacije Montaža, Gradski vodovod, Kanalizacija, Servis, Tehnički plinovi, Projektni biro, Komercijala i Stručne službe kako je prikazano na [Slika 5.1]. [14]



**Slika 5.1 Organizacija Poduzeća Vodovod – Osijek**

Početkom 21. stoljeća Poduzeće Vodovod – Osijek mijenja oblik organizacije u društvo s ograničenom odgovornošću – VODOVOD – OSIJEK d.o.o..

Zakon o vodama (NN 56/2013) pred Društvo je postavilo niz aktivnosti potrebnih za nastavak kontinuiranog poslovanja. Jedna od aktivnosti bila je i reorganizacija te novonastalo Društvo, koje djeluje i dan danas, promijenilo strukturu tj. izdvojeni su određeni tržišni dijelovi. Tako je organizacija današnjeg Društva prikazana na [Slika 5.2].



**Slika 5.2 Organizacija Društva VODOVOD – OSIJEK d.o.o.**

Danas je VODOVOD – OSIJEK d.o.o. moderno trgovačko društvo s preko 350 zaposlenika. Osnovna djelatnost Društva je pružanje vodnih usluga u koje prvotno spadaju obrada i distribucija pitke vode te odvodnja otpadnih voda.

Uz navedene osnovne djelatnosti, VODOVOD – OSIJEK d.o.o. bavi se još nekim aktivnostima kao što su:

- projektiranje, građenje i nadzor nad gradnjom
- ispitivanje kvalitete vode
- izvođenje priključaka na komunalne vodne građevine
- uvođenje instalacija
- građevinski radovi
- zdenci (izvedba, revitalizacija, sanacija, testiranje...)

## 5.2. Misija, vizija i ciljevi

Društva s jasno definiranom misijom, vizijom i ciljevima, koja znaju povezati svoje resurse s okruženjem i tržištem na kojem se nalaze, na glasu su kao uređena i uspješna društva. Uspješnost na tržištu može se mjeriti različitim kriterijima i pokazateljima koji daju jasnu sliku o stanju unutar poduzeća ili društva. Imajući u vidu navedeno, VODOVOD – OSIJEK d.o.o. vrlo precizno definira svoju misiju, viziju i ciljeve.

### **Vizija:**

Vizija Društva je postizanje zadanih ciljeva uz najviše standarde kvalitete, koristeći suvremene znanstvene tehnologije i metode vodeći pri tome brigu o zaštiti okoliša i oslanjajući se na vlastite tehničko-tehnološke i ljudske potencijale, na principima održivog razvoja. [14]

### **Misija:**

- sigurna opskrba kvalitetnom pitkom vodom
- kvalitetna usluga odvodnje otpadnih voda
- razvoj moderne infrastrukture
- usklađenost sa zaštitom okoliša i interesima lokalne zajednice

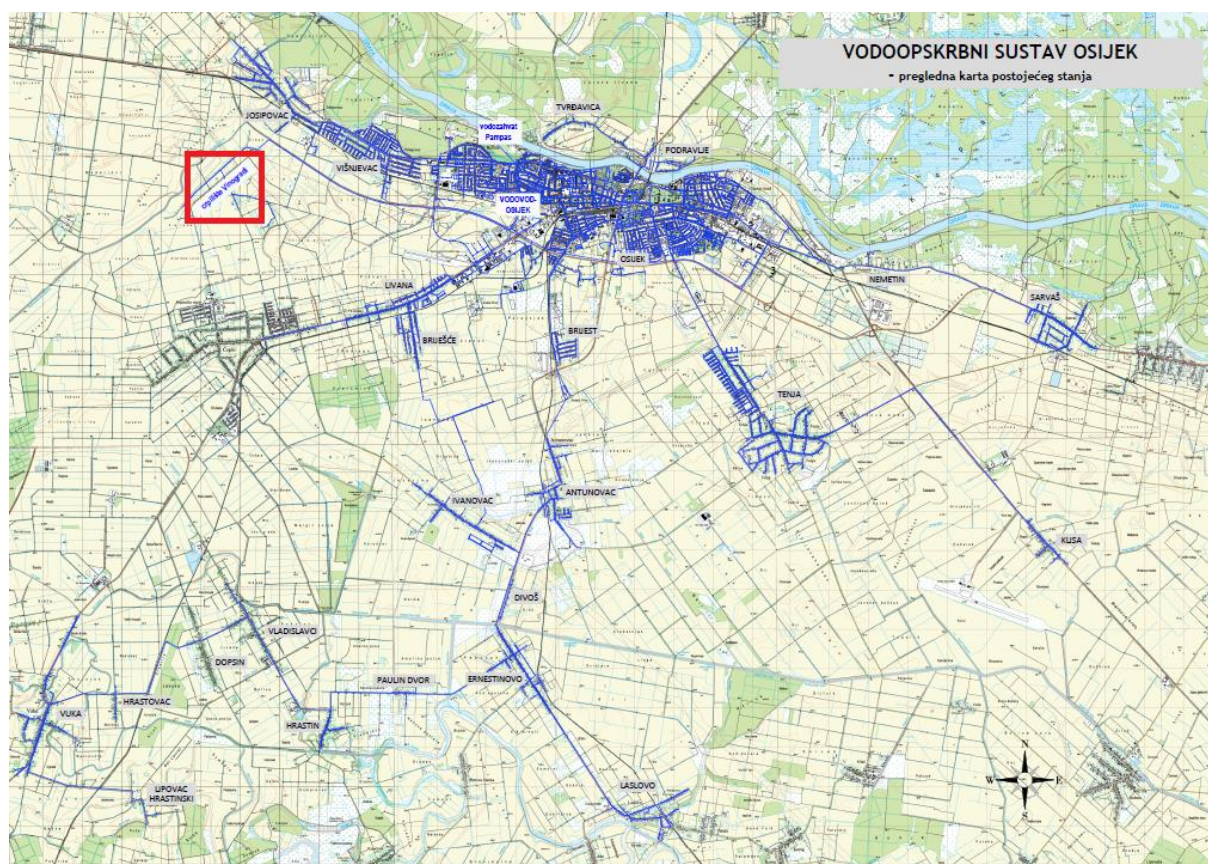
### **Ciljevi:**

- povećati učinkovitost poslovanja
- razvijati timski rad
- visoka odgovornost zaposlenika
- stalno usavršavanje ljudskih potencijala
- unapređivanje poslovanja
- uvođenje suvremenih informatičkih rješenja
- unapređenje poslovnih procesa

### 5.3. Analiza tehnološkog procesa obrade vode za ljudsku potrošnju

VODOVOD – OSIJEK d.o.o. zbog svoje je funkcije od iznimne važnosti za Grad Osijek, njegova prigradska naselja te okolne općine. Proizvodnjom i distribucijom pitke vode i odvođenjem otpadnih voda omogućava osnovne životne uvjete za nešto više od 100 000 ljudi.

Vodoopskrbni sustav opskrbljuje pitkom vodom Grad Osijek, prigradska naselja Višnjevac, Josipovac, Brijesće, Brijest, Tenja, Klisu, Sarvaš, Podravlje i Tvrđavicu te veliki broj sela iz obližnjih općina. Na [Slika 5.3] dan je prikaz vodoopskrbne mreže.



**Slika 5.3 Vodoopskrba mreža grada Osijeka i okolice [14]**

Značajke vodoopskrbnog sustava prema [14] su:

- Duljina vodoopskrbne mreže: približno 550 km
- Broj vodovodnih priključaka: 27 000
- Broj korisnika (domaćinstvo): 52 259
- Broj korisnika (gospodarstvo): 3 470

Tehnološki proces obrade vode za ljudsku potrošnju pomoću kojeg se uspješno uklanjaju određene tvari (supstance) ili se dovode do željene razine (MDK) koju propisuje zakon (4.2 *Parametri i metrika zdravstvene ispravnosti vode*), u sklopu Vodovoda – Osijek može se podijeliti u faze prikazane pomoću [Tablica 5.1]. Voda se prerađuje kemijsko – biološkim postupcima na tri odvojene linije.

**Tablica 5.1 Faze procesa obrade vode za ljudsku potrošnju (Vodovod – Osijek)**

1. faza	<b>Crpljenje sirove vode</b>
2. faza	<b>Aeracija</b>
3. faza	<b>Predoksidacija</b>
4. faza	<b>Koagulacija</b>
5. faza	<b>Flokulacija</b>
6. faza	<b>Taloženje</b>
7. faza	<b>Filtriranje i nitrifikacija</b>
8. faza	<b>Dezinfekcija</b>
9. faza	<b>Crpljenje u vodoopskrbnu mrežu</b>
	<b>Nadzor i kontrola kvalitete vode*</b>

\* Tehnološki proces vode za ljudsku potrošnju iznimno je složen postupak kojeg je potrebno stalno nadzirati.

Upravo je zbog toga kao međufaza uvedena kontrola kvalitete vode.

U nastavku će biti prikazana i ukratko opisana svaka pojedina faza tehnološkog procesa obrade vode za ljudsku potrošnju u sklopu postrojenja Vodovod – Osijek.



### 5.3.1. Crpljenje sirove vode

Tehnološki proces obrade vode započinje crpljenjem sirove vode iz prirodnog izvorišta. Vodovod – Osijek osiguran je glavnim i rezervnim crpilištem vode. Glavno crpilište čini 18 bunara (zdenaca) pod skupnim nazivom crpilište Vinogradi. Prosječna pojedinačna izdašnost svakog zdenca iznosi oko 40 l/s. Ukupni instalirani kapacitet crpki iznosi 720 l/s. Crpilište vinogradi označeni su crvenim kvadratom na vodoopskrbnoj mreži [Slika 5.3]. Rezervno ili dopunsko crpilište obuhvaća zahvat sirove vode iz rijeke Drave te nosi naziv Pampas. Kapacitet rezervnog crpilišta Pampas iznosi 350 l/s i koristi se samo u slučaju nefunkcionalnosti glavnog crpilišta Vinogradi.



**Slika 5.4 Bunari na crpilištu Vinogradi [14]**

Na [Slika 5.4] prikazani su bunari na crpilištu Vinogradi. Samo crpilište nalazi se u vodozaštitnom području gdje se vrlo strogo poštuju mjere za sprječavanje onečišćenja. Prosječna dubina bunara iznosi 150 metara. Voda zahvaćena iz njih bakteriološki je ispravna, ali sadrži, tipično za podzemne vode povišenu koncentraciju željeza, mangana, arsena i amonijaka.



### 5.3.2. Aeracija

Nakon dolaska sirove vode s crpilišta Vinogradi započinje proces aeriranja vode. On podrazumijeva dovođenje sirove vode u kontakt s atmosferskim zrakom. Ono što se postiže ovim postupkom je sljedeće:

- obogaćivanje sirove vode kisikom
- otplinjavanje ugljikovog dioksida ( $\text{CO}_2$ ) i sumporovodika ( $\text{H}_2\text{S}$ )
- ublažavanje mirisa i okusa vode
- oksidacija željeza, mangana i arsena u otopljenom stanju



**Slika 5.5** Aeriranje sirove vode

Na [Slika 5.5] prikazan je proces aeriranja bunarske sirove vode. Nakon aeracije voda sadrži oko 8 mg  $\text{O}_2$ /l vode. Ukoliko se voda crpi s rezervnog izvorišta Pampas, proces aeracije nije potrebno provoditi.

### 5.3.3. Predoksidacija


Procesom predoksidacije pospješuje se separacija čestica u tehnologiji obradi voda. U ovom pogonu vrši se doziranje 1%-tne otopine kalijeva permanganata ( $\text{KMnO}_4$ ). Na [Slika 5.6] prikazan je sustav za doziranje kalijeva permanganata.



**Slika 5.6** Sustav za doziranje kalijeva permanganata

#### 5.3.4. Koagulacija

Dodavanjem koagulantata započinje proces koagulacije kojim se destabiliziraju čestice – koloidi te postaju pogodni za aglomeraciju (formiranje veće tvorevine) u sljedećoj fazi obrade. Koagulacije se vrši doziranjem 40%-tne otopine željezovog klorida ( $\text{FeCl}_3$ ).



**Slika 5.7** Sustav za doziranje željezovog klorida

Na [Slika 5.7] prikazan je sustav i upravljačka ploča za doziranje koagulantata za svaku od tri linije posebno.

### 5.3.5. Flokulacija

Flokulacija je fizikalno – kemijski postupak kojim se koloidno dispergirane tvari u vodi nakon doziranja sredstva za flokulaciju aglomeriraju u veće, lakše filtrirajuće nakupine. Flokulacija se vrši doziranjem 0,05%-tne otopine polielektrolita tj. poli-akril-amida (PAA). Na [Slika 5.8] prikazan je sustav za doziranje flokulanta.



Slika 5.8 Sustav za doziranje flokulanta PAA

### 5.3.6. Taloženje

Taloženje se vrši na tri linije. Na liniji 1 odvija se u 6 taložnika i 4 precipitatora; na liniji 2 u 2 akceleratora; na liniji 3 nema taloženja već je filternica 3 projektirana da ima dvovrsnu ispunu od kvarcnog pijeska i hidroantracita. Kod taložnika je bitno napomenuti da ih je potrebno odmuljivati u određenim vremenskim intervalima, a nastali mulj se odvodi u postrojenje za obradu otpadnih voda. Na [Slika 5.9] prikazan je sustav za taloženje (akcelerator).



Slika 5.9 Sustav za taloženje



### 5.3.7. Filtriranje i nitrifikacija

Filtriranje i nitrifikacija vrše se u filtrirnicama 1, 2 i 3 na dvovrsnim filtrima. Filtrirnice su podijeljene na više filtarskih polja, a kapacitet filtriranja je oko 900 l/s vode. Nitrifikacija se vrši preko filtarske ispune pod djelovanjem bakterija (*Nitrosomonas* i *Notrobacter*). Filteri se kao i taložnici moraju isprati, a voda od pranja odvodi se u postrojenje za obradu otpadnih voda. Na [Slika 5.10] prikazan je sustav za filtraciju vode.



Slika 5.10 Sustav za filtraciju vode

### 5.3.8. Dezinfekcija

Dezinfekcija vode provodi se kako bi se uklonili mikroorganizmi (bakterije, spore, virusi, ličinke...). Dezinfekcija se u sustavu Vodovoda – Osijek provodi plinovitim klorom tako da se voda, prije skladištenja u 4 vodospremnika, dezinficira proporcionalno protoku vode s 0,5 – 0,7 mg/l. [14]

### 5.3.9. Crpljenje vode u vodoopskrbnu mrežu

Crpljenje vode do potrošača vrši se crpnom stanicom vodom iz vodospremnika. Voda se crpi tako da se održava tlak (pritisak) vode od 5 bara na ulaz u vodoopskrbnu mrežu. Prilikom crpljenja vode prisutna je i dodezinfekcija. Na [Slika 5.11] prikazan je sustav za crpljenje vode u vodoopskrbnu mrežu te navedena razina tlaka (pritiska) vode.

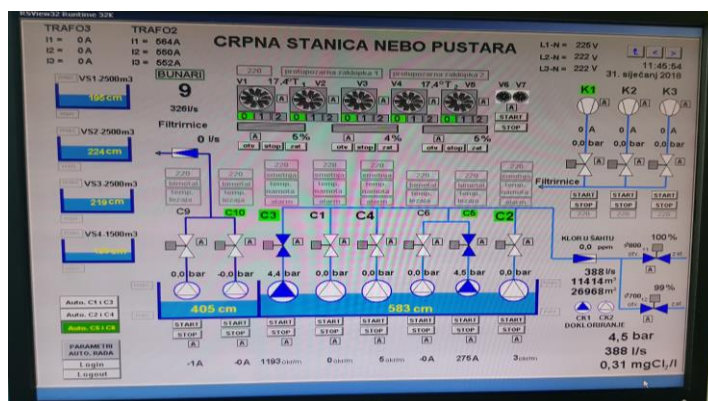


Slika 5.11 Sustav za crpljenje vode u vodoopskrbnu mrežu

### 5.3.10. Nadzor procesa obrade i kontrola kvalitete vode

Nadzor i upravljanje sustava proizvodnje i distribucije vode provodi se automatski pomoću računala i programibilnih logičkih kontrolera (eng. *Programmable Logic Controller* – PLC). Na [Slika 5.12] prikazan je implementirani sustav za nadzor i prikupljanje podataka (eng. *Supervisory Control And Data Acquisition* – SCADA). Također, cjelokupni proces obrade vode pod stalnim je nadzorom internog laboratorija pitke vode. U njemu se svakodnevno analizira kvaliteta vode s crpilišta, kontrolira tijekom tehnološkog procesa kao i kvaliteta prerađene vode.

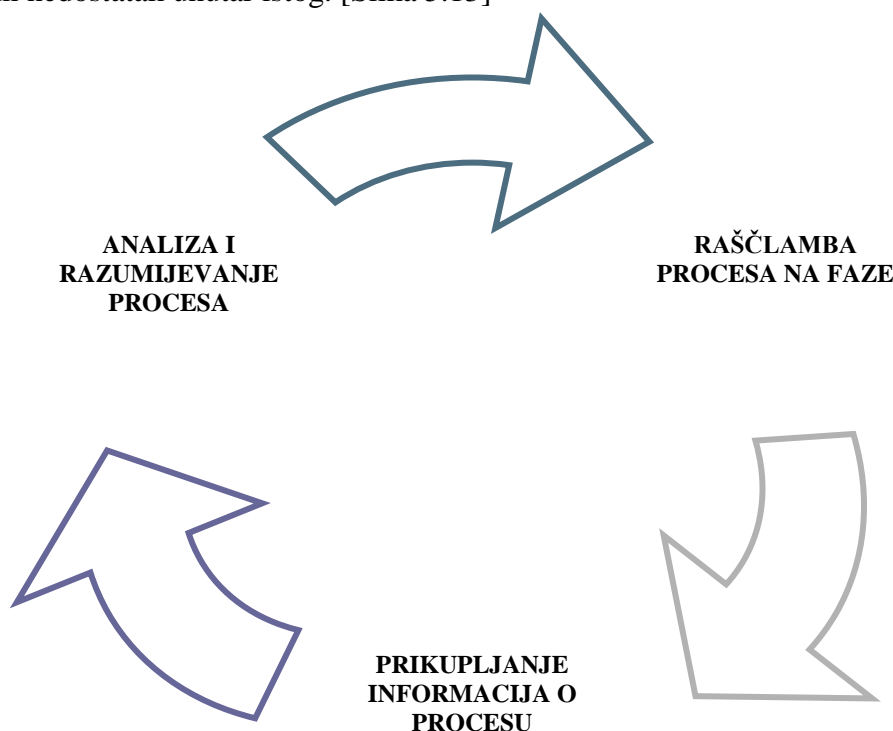
Slika 5.12 SCADA sustav za nadzor i prikupljanje podataka



#### 5.4. Funkcijska mapa toka vrijednosti

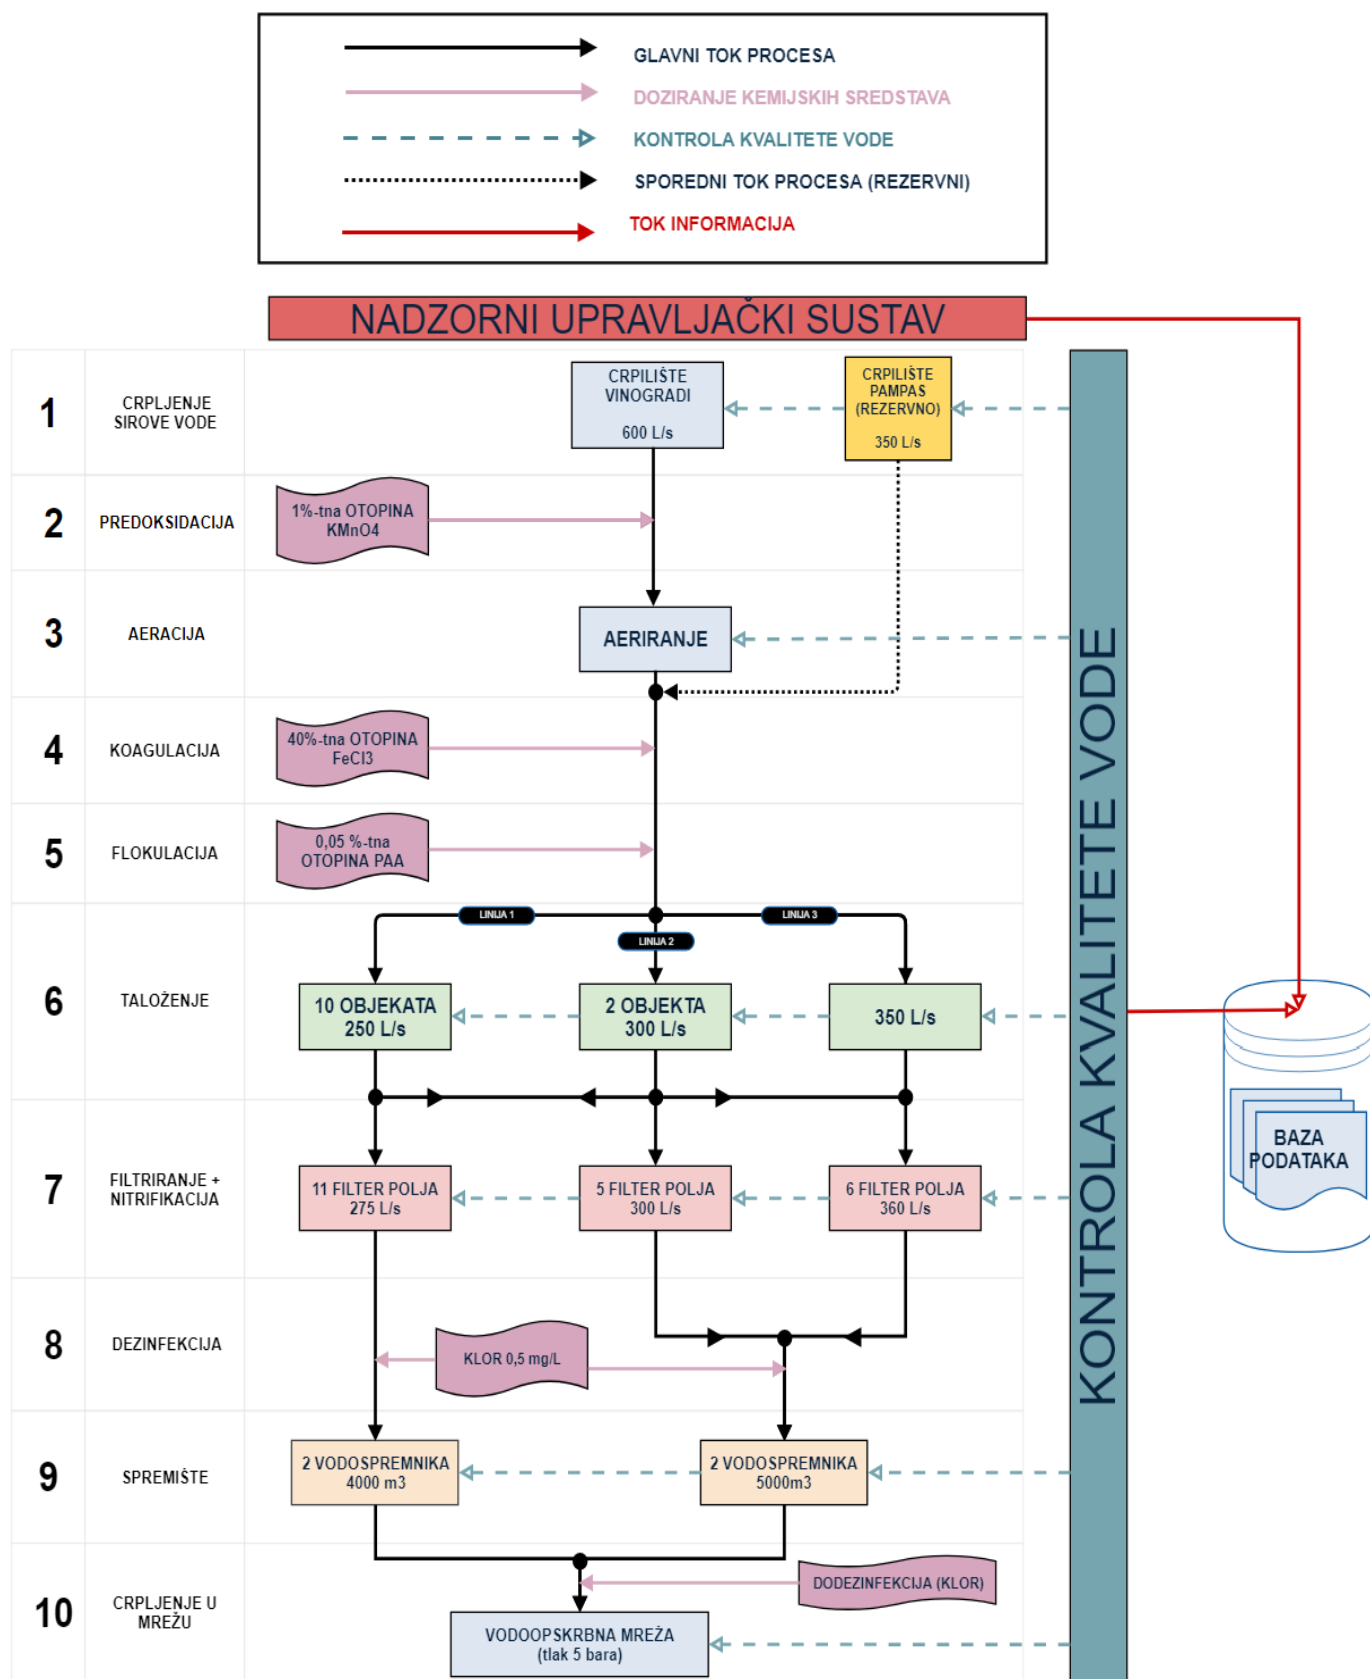
Tok materijala i informacija zajedničkim se imenom naziva tok vrijednosti (eng. *Value Stream*). Funkcijska mapa toka vrijednosti (eng. *Value Stream Mapping* – VSM) je grafički prikaz promatranog procesa. Proces i mogu podijeliti na proizvodne i uslužne. VSM se može definirati i kao grafička simulacija procesa.

Kako bi se proces obrade vode za ljudsku potrošnju prikazao ovom metodom, potrebno je provesti određene aktivnosti kao što su analiza i razumijevanje promatranog procesa, određivanje faza promatranog procesa te prikupljanje informacija o procesu. Ovi bi se koraci, nakon izrade funkcijske mape toka vrijednosti, trebali ponavljati u određenim vremenskim periodima kako bi se promatrani proces kontinuirano nadgledao, unaprijedio, ali isto tako uočio određeni nedostatak unutar istog. [Slika 5.13]



Slika 5.13 Aktivnosti VSM metode

Nakon što je provedena detaljna analiza procesa obrade vode za ljudsku potrošnju u poduzeću VODOVOD – OSIJEK d.o.o. u poglavlju 5.3 *Analiza tehnološkog procesa obrade vode za ljudsku potrošnju*, izvršena raščlamba na faze te prikupljene informacije i podaci, slijedi izrada funkcijske mape toka vrijednosti. [Slika 5.14]



Slika 5.14 Funkcijska mapa toka vrijednosti (VODOVOD – OSIJEK d.o.o.)

## 6. PRIMJENA STATISTIČKE KONTROLE PROCESA

Primjena statističke kontrole procesa provest će se na sustavu za obradu vode za ljudsku upotrebu poduzeća VODOVOD – OSIJEK d.o.o.

Nakon što je proces obrade vode za ljudsku upotrebu detaljno analiziran, metrika konačnog proizvoda (vode) detaljno opisana te izrađena funkcijska mapa toka vrijednosti, sve je spremno za primjenu SPC metode.

### 6.1. Specifikacija podataka

U nastavku će se prikazati specifikacija potrebnih podataka za provedbu SPC metode.

**Tablica 6.1 Specifikacija podataka**

<b>Odabrani elementi</b>	amonijak, željezo, arsen
<b>Godina uzorkovanja</b>	2017.
<b>Broj uzoraka</b>	240 (20 po svakom mjesecu)
<b>Veličina uzorka</b>	1

**Tablica 6.2 MDK vrijednosti odabranih elemenata**

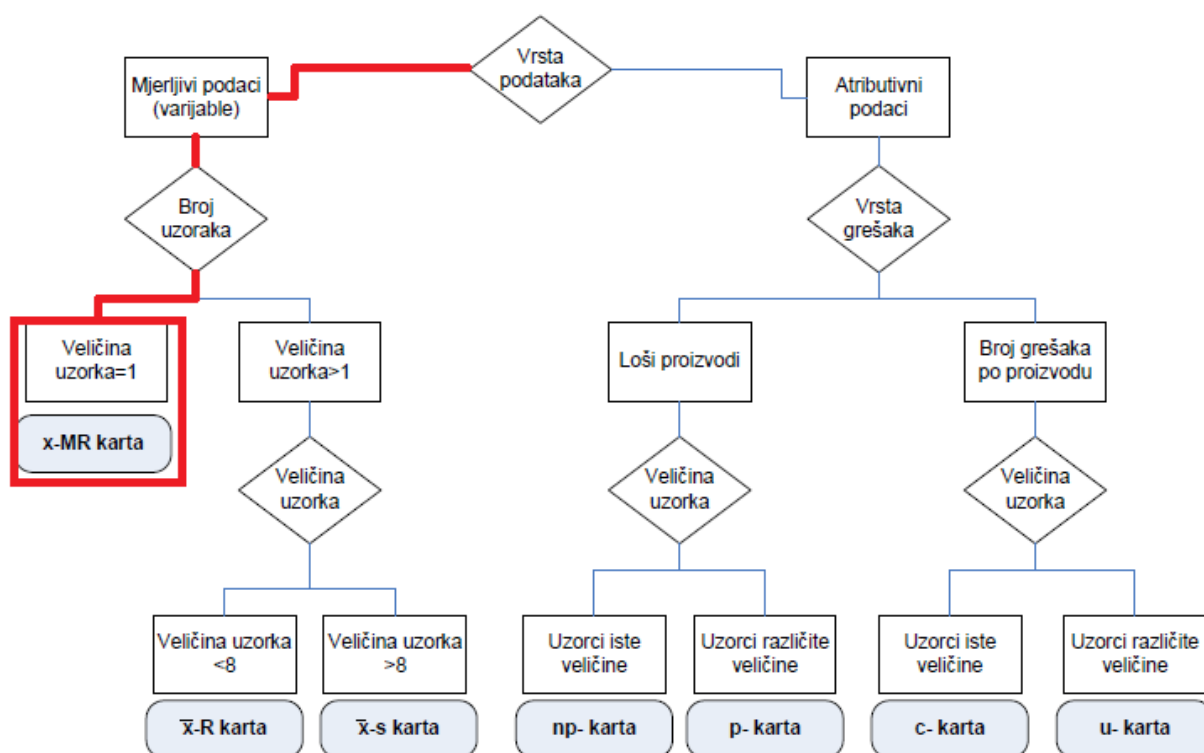
ELEMENT	JEDINICA	MDK vrijednost
Amonijak	mg/l	0,5
Željezo	µg/l	200
Arsen	µg/l	50 (10)

U ovom radu provodit će se prva faza SPC metode (SPC I) prema poglavlju 2.2 *Faze provođenja SPC metode*.



## 6.2. Odabir kontrolnog dijagrama

Kako bi uspješno primijenila SPC metoda, potrebno je odabrati odgovarajući kontrolni dijagram. Ključnu ulogu pri odabiru kontrolnog dijagrama ima broj i veličina uzorka. U ovom slučaju prema [Tablica 6.1] broj uzoraka je 240, a veličina svakog je 1. Takvi se podaci često nazivaju i pojedinačni promatrani podaci (eng. *Individual Observed Data*). Na [Slika 6.1] prikazan je odabir kontrolnog dijagrama pomoću definiranog algoritma.

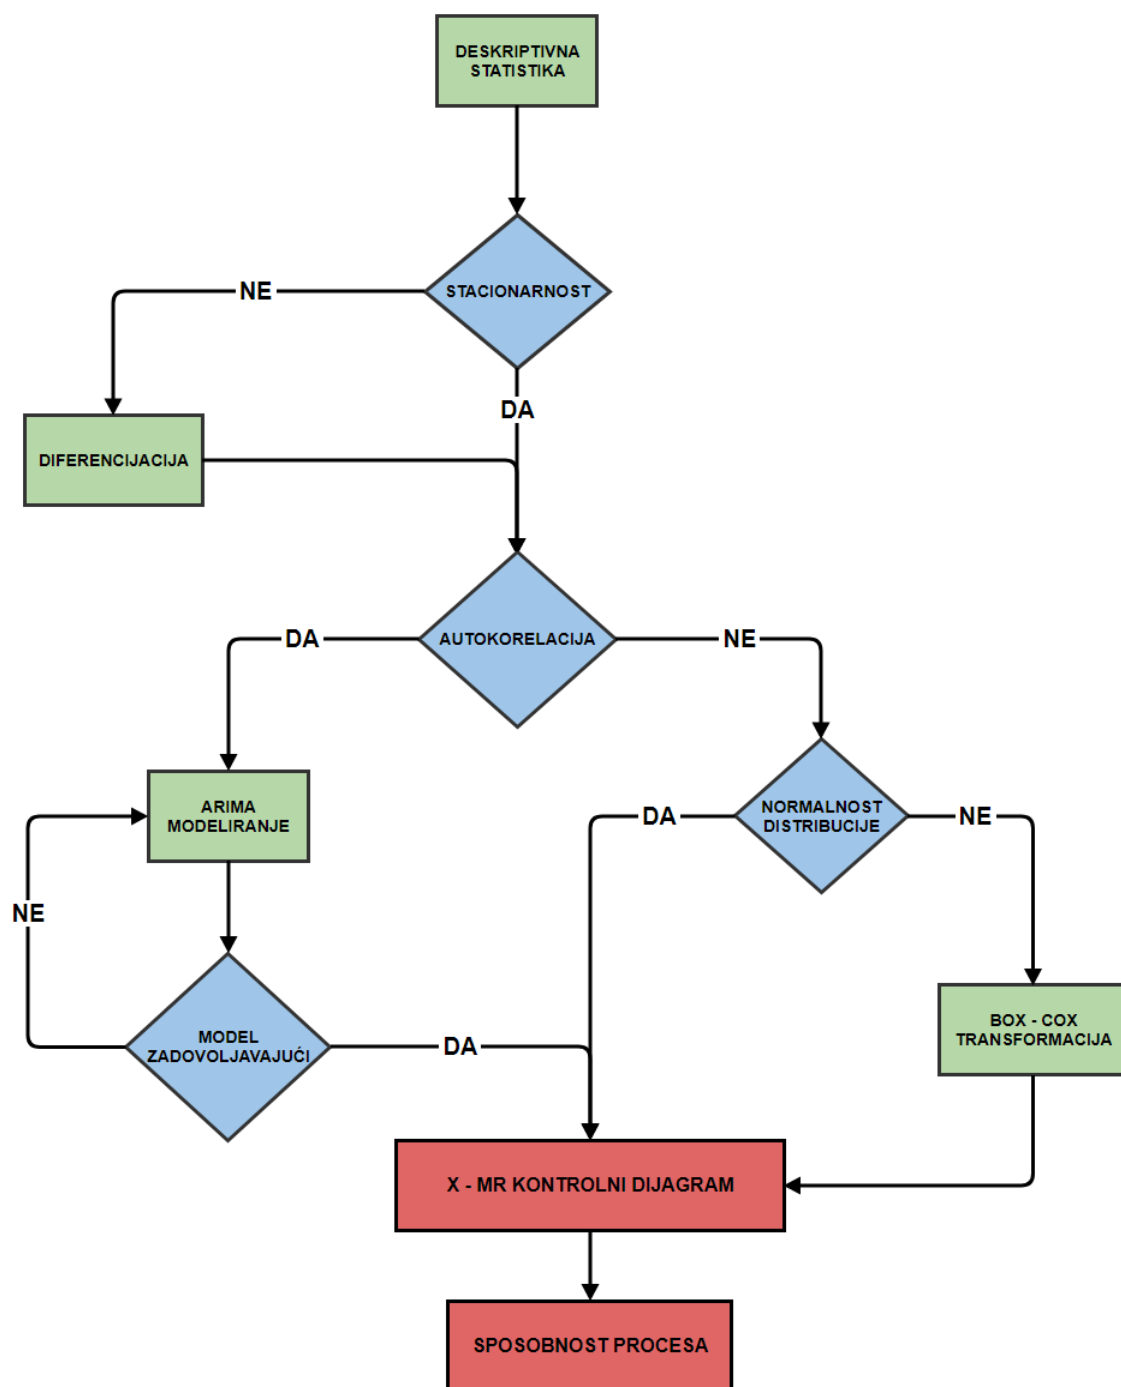


Slika 6.1 Odabir kontrolnog dijagrama

**Odabran je X – MR kontrolni dijagram.**

### 6.3. Algoritam provedbe SPC metode

U nastavku je prikazan algoritam transformacije (prilagođavanja) podataka vremenske serije kako bi se ispravno mogla provesti SPC metoda tj. stvorili preduvjeti za ispravno donošenje zaključaka o procesu. [Slika 6.2]



Slika 6.2 Algoritam SPC metode

U nastavku će ukratko biti objašnjeni pojmovi iz algoritma [Slika 6.2] bez predubokog zadiranja u „matematički aparat“ koji stoji iza svakog postupka.

Prikupljeni podaci o tehnološkom procesu obrade vode tvore vremenski niz ili vremensku seriju koja je skup kronološki uređenih podataka kojima se prate promjene promatranog procesa. Glavna značajka koja će opisivati stanje procesa bit će razlika kvalitete vode prije tretiranja (sirova voda) i kvaliteta vode nakon tretiranja (obrađena voda) tj. koncentracija određenog elementa koja je uklonjena navedenim procesom.

#### ➤ **Deskriptivna statistika**

Deskriptivna statistika je disciplina koja se bavi kvalitativnim i kvantitativnim opisivanjem i prikazivanjem glavnih značajki prikupljenih podataka.

#### ➤ **Stacionarnost podataka**

Grafička provjera egzistencije trenda u skupu promatranih podataka.

#### ➤ **Diferencijacija podataka**

Proces izračunavanja razlike između podataka vremenske serije radi uklanjanja trenda među promatranim podacima. Koristit će se diferencijacija prvog reda koja predstavlja pojedinačnu mjeru promjene pojave u uzastopnom razdoblju.

#### ➤ **Autokorelacija**

Autokorelacija predstavlja korelaciju između promatranih podataka vremenske serije. Provjerava se ACF (eng. *Autocorrelation Function*) i PACF (eng. *Partial Autocorrelation Function*) funkcijama.

#### ➤ **ARIMA modeliranje**

ARIMA (eng. *Autocorrelation Integrated Moving Average*) modeliranje predstavlja proces izgradnje modela za predviđanje budućeg stanja promatranog procesa. U ovom slučaju će se koristiti kao metoda smanjivanja razine autokorelacije unutar vremenske serije.

#### ➤ **Box – Cox transformacija**

Transformacija ne-normalnih podataka tako da se mogu opisati normalnom distribucijom.

## 6.4. Amonijak

U nastavku će biti prikazana primjena SPC metode na primjeru koncentracije amonijaka.

### ➤ Set podataka


**Tablica 6.3 Koncentracija amonijaka prije procesa obrade vode [mg/l]**

16 Siječanj	17 Veljača	18 Ožujak	19 Travanj	20 Svibanj	21 Lipanj	22 Srpanj	23 Kolovoz	24 Rujan	25 Listopad	26 Studenj	27 Prosinac
2,731	2,263	2,336	2,357	2,45	2,474	2,336	2,595	2,431	2,302	2,369	2,338
2,501	2,253	2,406	2,401	2,283	2,389	2,301	2,36	2,553	2,461	2,432	2,594
2,244	2,308	2,503	2,477	2,555	2,245	2,413	2,277	2,403	2,642	2,448	2,552
2,578	2,517	2,314	2,455	2,523	2,39	2,416	2,244	2,414	2,471	2,508	2,496
2,368	2,596	2,423	2,372	2,377	2,327	2,461	2,401	2,363	2,483	2,464	2,448
2,378	2,298	2,401	2,805	2,419	2,384	2,301	2,385	2,318	2,369	2,296	2,518
2,255	2,258	2,454	2,5	2,398	2,558	2,401	2,478	2,428	2,471	2,44	2,354
2,589	2,373	2,461	2,53	2,38	2,26	2,295	2,311	2,849	2,326	2,445	2,639
2,506	2,25	2,4	2,475	2,472	2,488	2,278	2,511	2,45	2,4	2,369	2,564
2,372	2,239	2,402	2,355	2,535	2,328	2,214	2,401	2,464	2,369	2,309	2,403
2,276	2,44	2,308	2,518	2,412	2,42	2,743	2,311	2,491	2,34	2,594	2,457
2,301	2,649	2,356	2,624	2,34	2,684	2,258	2,247	2,348	2,504	2,3	2,501
2,434	2,439	2,453	2,588	2,558	2,405	2,358	2,842	2,347	2,378	2,411	2,466
2,526	2,277	2,674	2,577	2,508	2,401	2,216	2,329	2,293	2,488	2,447	2,529
2,284	2,265	2,589	2,492	2,428	2,269	2,365	2,293	2,496	2,404	2,401	2,584
2,632	2,151	2,447	2,501	2,351	2,427	2,417	2,283	2,432	2,411	2,502	2,468
2,406	2,427	2,541	2,579	2,559	2,42	2,398	2,507	2,457	2,397	2,422	2,857
2,544	2,438	2,509	2,873	2,447	2,259	2,276	2,423	2,537	2,419	2,356	2,538
2,227	2,544	2,369	2,467	2,492	2,311	2,446	2,427	2,502	2,431	2,244	2,489
2,324	2,295	2,436	2,5	2,564	2,271	2,221	2,648	2,98	2,428	2,301	2,506

**Tablica 6.4 Koncentracija amonijaka nakon procesa obrade vode [mg/l]**

1 Siječanj	2 Veljača	3 Ožujak	4 Travanj	5 Svibanj	6 Lipanj	7 Srpanj	8 Kolovoz	9 Rujan	10 Listopad	11 Studenj	12 Prosinac
0,098	0,098	0,107	0,1	0,104	0,102	0,113	0,105	0,101	0,101	0,101	0,095
0,089	0,095	0,105	0,101	0,112	0,106	0,1	0,109	0,12	0,1	0,092	0,098
0,085	0,096	0,103	0,098	0,106	0,102	0,115	0,105	0,118	0,103	0,092	0,105
0,091	0,084	0,09	0,092	0,096	0,105	0,108	0,103	0,117	0,114	0,111	0,098
0,09	0,085	0,107	0,099	0,097	0,095	0,11	0,108	0,099	0,096	0,103	0,106
0,088	0,087	0,109	0,106	0,092	0,109	0,1	0,098	0,101	0,093	0,106	0,106
0,088	0,087	0,102	0,106	0,09	0,098	0,11	0,101	0,111	0,09	0,115	0,099
0,098	0,09	0,093	0,11	0,098	0,095	0,098	0,101	0,112	0,09	0,101	0,1
0,099	0,091	0,095	0,099	0,095	0,106	0,098	0,105	0,103	0,095	0,098	0,098
0,097	0,084	0,095	0,108	0,101	0,109	0,093	0,098	0,123	0,092	0,092	0,098
0,1	0,087	0,093	0,102	0,103	0,112	0,112	0,103	0,13	0,098	0,099	0,098
0,099	0,098	0,098	0,107	0,099	0,115	0,107	0,097	0,101	0,107	0,092	0,091
0,098	0,091	0,092	0,114	0,103	0,105	0,117	0,109	0,105	0,098	0,096	0,103
0,099	0,089	0,092	0,092	0,117	0,119	0,102	0,093	0,096	0,104	0,1	0,104
0,098	0,092	0,092	0,0984	0,096	0,12	0,104	0,091	0,104	0,098	0,112	0,101
0,104	0,094	0,096	0,098	0,098	0,11	0,109	0,097	0,099	0,103	0,104	0,095
0,096	0,103	0,098	0,098	0,092	0,104	0,102	0,103	0,096	0,098	0,108	0,099
0,092	0,112	0,105	0,108	0,099	0,102	0,102	0,097	0,095	0,102	0,107	0,102
0,091	0,118	0,094	0,094	0,105	0,11	0,115	0,102	0,122	0,105	0,099	0,094
0,09	0,119	0,093	0,101	0,096	0,105	0,11	0,092	0,105	0,11	0,107	0,097

## ➤ Deskriptivna statistika



Slika 6.3 Numerička i grafička analiza (amonijak)


Dijagrami sa [Slika 6.3] temelje se na podacima koji predstavljaju razliku koncentracije amonijaka u vodi prije i nakon provedbe tehnološkog procesa obrade, odnosno koncentraciju amonijaka koja se uklonila navedenim tretmanom. Iz njih se mogu iščitati osnovni parametri:

- srednja vrijednost: 2,33 mg/l
- medijan: 2,317 mg/l
- mod: više vrijednosti (frekvencija: 5)
- standardna devijacija: 0,127 mg/l
- raspon: 0,818 mg/l

Iz P-P (eng. *Probability – Probability*) dijagrama može se zaključiti da podaci prate normalnu razdiobu. Do istog zaključka se moglo doći i usporedbom p vrijednosti K – S (*Kolmogorov – Smirnov*) testa koja je veća od razine značajnosti  $\alpha$ :

- $p \approx 0,2 > \alpha = 0,05$


➤ **Stacionarnost procesa**




**Slika 6.4 Stacionarnost procesa (amonijak)**

U dijagramu na [Slika 6.4] prikazana je varijacija procesa po kvartalima. Može se uočiti da u procesu postoji značajna varijacija međutim isto tako da ne postoji značajni trend. Zaključak je da proces zadovoljava uvjet stacionarnosti te da nije potrebno upotrijebiti diferencijaciju podataka. Isto tako, bez koraka diferencijacije, ARIMA modeliranje postaje ARMA modeliranje.

### ➤ Autokorelacija podataka




**Slika 6.5 Autokorelacija – ACF (amonijak)**




**Slika 6.6 Autokorelacija – PACF (amonijak)**

Iz ACF i PACF sa [Slika 6.5] i [Slika 6.6] može se zaključiti da postoji autokorelacija među podacima te je potrebno provesti ARMA modeliranje.

## ➤ ARMA modeliranje



Slika 6.7 Autokorelacija – ACF – ARMA (amonijak)




Slika 6.8 Autokorelacija – PACF – ARMA (amonijak)

Nakon provedenog ARMA modeliranja, autokorelacija je smanjena kako prikazuju [Slika 6.7] i [Slika 6.8]. Nakon ovog koraka dobiva se transformirani set podataka koji je adekvatan za primjenu X – MR kontrolnog dijagrama.

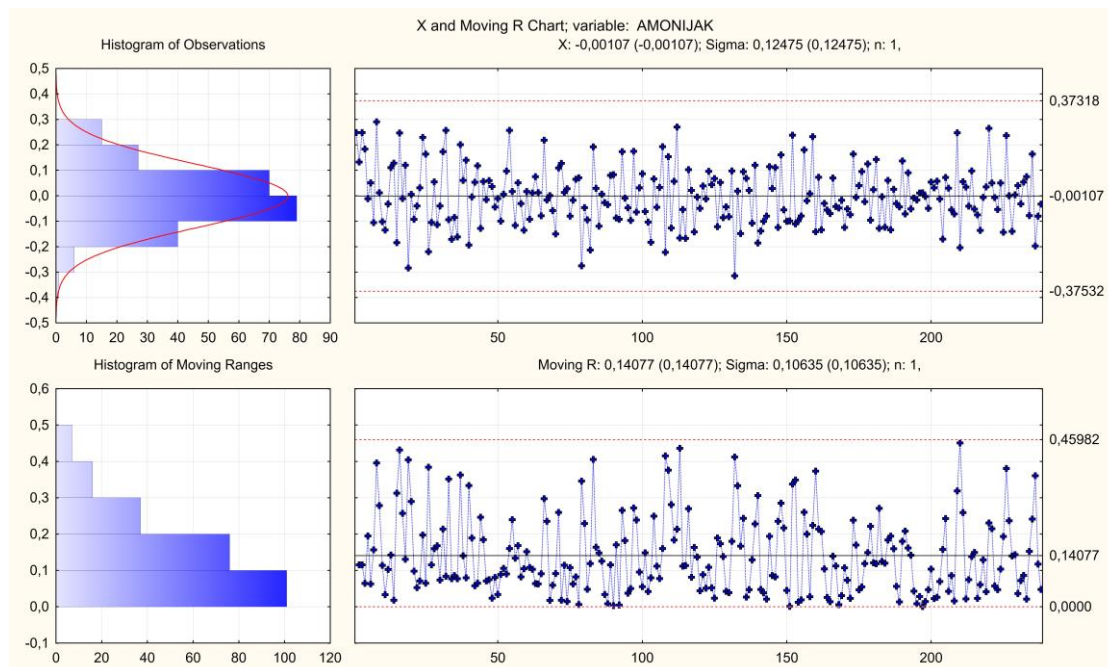


## ➤ X – MR kontrolni dijagram



Slika 6.9 X – MR kontrolni dijagram (amonijak)

Promatranjem X – MR kontrolnog dijagrama može se uočiti da proces sadrži dvije točke izvan kontrolnih granica - točka 168 i točka 141. Sljedeći korak je uklanjanje te dvije točke te izrada novog kontrolnog dijagrama kako bi se ustanovile konačne kontrole granice koje će se koristiti za buduće promatranje procesa.



Slika 6.10 Korigirani X – MR kontrolni dijagram (amonijak)


Nove kontrole granice iznose:

X KONTROLNI DIJAGRAM	MR KONTROLNI DIJAGRAM
UCL = 0,37318	UCL = 0,45982
LCL = -0,37532	LCL = 0

Ukoliko se u budućnosti pojavi vrijednost (nakon transformacije) koja prelazi ove kontrolne granice, to predstavlja indikaciju da se pojavio poseban uzrok koji potiče prekomjernu varijaciju te ga je potrebno pronaći i ukloniti. Bitno je naglasiti da proces ne proizvodi nužno loše proizvode kod ovakve pojave (u ovo slučaju bi to značilo vodu koja ne zadovoljava propisane zakonske vrijednosti), već da proces odstupa od uobičajenog rada.

### ➤ Sposobnost procesa

Nakon što je zadovoljen uvjet stabilnosti procesa, potrebno je provesti analizu sposobnosti procesa.



**Slika 6.11 Sposobnost procesa (amonijak)**

Zakonom je propisana samo maksimalna dopuštena koncentracija amonijaka u vodi za piće koja prema prije navedenoj tablici iznosi 0,5 mg/l. Sposobnost procesa je, s obzirom na propisanu MDK vrijednost, izvrsna što se može vidjeti i s dijagrama na [Slika 6.11]. Demonstrirana sposobnost procesa iznosi 12,15 uzevši u obzir 6 $\sigma$  razinu kvalitete.

## 6.5. Željezo

U nastavku će biti prikazana primjena SPC metode na primjeru koncentracije željeza.

### ➤ Set podataka


**Tablica 6.5 Koncentracija željeza prije procesa obrade vode [μg/l]**

16 Siječanj	17 Veljača	18 Ožujak	19 Travanj	20 Svibanj	21 Lipanj	22 Srpanj	23 Kolovoz	24 Rujan	25 Listopad	26 Studenj	27 Prosinac
1290	1408	1518	1397	1313	1249	1491	1368	1300	1435	1300	1357
1389	1348	1443	1528	1415	1243	1475	1361	1364	1445	1357	1321
1406	1377	1307	1447	1400	1217	1317	1339	1251	1382	1270	1447
1364	1369	1437	1359	1446	1387	1366	1407	1255	1328	1388	1404
1445	1487	1314	1350	1390	1319	1351	1387	1282	1385	1310	1257
1446	1349	1329	1385	1384	1381	1393	1419	1248	1424	1393	1299
1448	1311	1348	1322	1356	1335	1356	1396	1261	1442	1355	1225
1457	1394	1322	1336	1408	1451	1316	1316	1140	1373	1257	1270
1393	1425	1388	1349	1391	1420	1325	1422	1248	1329	1388	1262
1370	1464	1431	1228	1384	1348	1341	1211	1318	1303	1328	1307
1404	1526	1275	1299	1361	1465	1312	1285	1145	1328	1317	1394
1428	1529	1383	1446	1318	1346	1214	1468	1393	1500	1374	1443
1408	1385	1355	1351	1355	1481	1382	1328	1481	1378	1330	1338
1366	1315	1423	1438	1292	1183	1316	1377	1467	1321	1354	1403
1402	1445	1296	1284	1381	1346	1299	1330	1431	1250	1320	1455
1320	1406	1365	1360	1388	1407	1298	1322	1391	1409	1270	1478
1357	1423	1420	1366	1314	1389	1348	1497	1426	1373	1297	1341
1360	1432	1291	1568	1358	1377	1318	1420	1286	1336	1277	1587
1334	1361	1283	1352	1327	1404	1360	1345	1323	1322	1347	1530
1317	1624	1456	1385	1244	1459	1268	1311	1371	1332	1374	1443

**Tablica 6.6 Koncentracija željeza nakon procesa obrade vode [μg/l]**

1 Siječanj	2 Veljača	3 Ožujak	4 Travanj	5 Svibanj	6 Lipanj	7 Srpanj	8 Kolovoz	9 Rujan	10 Listopad	11 Studenj	12 Prosinac
5	12	13	18	5	14	22	5	13	18	5	16
25	32	8	15	5	21	5	5	6	11	23	5
22	24	21	19	20	23	9	5	18	10	12	5
10	26	8	10	5	11	5	6	5	9	13	21
27	12	6	10	5	5	5	28	12	10	20	11
15	9	5	5	5	6	5	17	18	5	15	20
17	5	6	18	15	11	11	5	16	11	6	9
32	6	14	22	29	5	10	6	19	22	10	5
38	28	24	5	7	6	5	6	5	15	24	10
26	12	12	5	5	7	5	5	13	8	11	16
35	14	8	5	7	5	5	12	14	18	5	5
28	9	23	11	5	20	18	5	18	5	16	5
38	18	9	6	25	17	5	7	5	5	15	16
35	56	21	20	6	12	9	5	5	15	14	6
14	38	7	10	5	17	5	5	13	7	19	5
24	22	5	10	5	34	5	5	5	8	9	9
21	16	16	8	6	5	9	5	11	8	24	6
5	20	22	25	7	5	5	5	26	18	6	5
23	8	6	22	7	5	5	8	6	5	9	5
13	17	8	9	12	5	9	12	6	8	13	5

## ➤ Deskriptivna statistika



Slika 6.12 Numerička i grafička analiza (željezo)


Dijagrami sa [Slika 6.12] temelje se na podacima koji predstavljaju razliku koncentracije željeza u vodi prije i nakon provedbe tehnološkog procesa obrade, odnosno koncentraciju željeza koja se uklonila navedenim tretmanom. Iz njih se mogu iščitati osnovni parametri:

- srednja vrijednost: 1352,40  $\mu\text{g/l}$
- medijan: 1351  $\mu\text{g/l}$
- mod: 1308  $\mu\text{g/l}$  (frekvencija: 5)
- standardna devijacija: 74,02  $\mu\text{g/l}$
- raspon: 486  $\mu\text{g/l}$

Iz P-P (eng. *Probability – Probability*) dijagrama može se zaključiti da podaci prate normalnu razdiobu. Do istog zaključka se moglo doći i usporedbom p vrijednosti K – S (*Kolmogorov – Smirnov*) testa koja je veća od razine značajnosti  $\alpha$ :

- $p \approx 0,2 > \alpha = 0,05$


### ➤ Stacionarnost procesa



**Slika 6.13 Stacionarnost procesa (željezo)**

U dijagramu na [Slika 6.13] prikazana je varijacija procesa po kvartalima. Može se uočiti da u procesu postoji značajna varijacija. Također, može se primijetiti da postoji trend opadanja koncentracije uklonjenog željeza tijekom vremena. Zaključak je da proces ne ispunjava uvjet stacionarnosti te da je potrebno provesti diferencijaciju prije ARIMA modeliranja.


### ➤ Diferencijacija podataka



**Slika 6.14 Diferencijacija podataka (željezo)**

Nakon diferencijacije prvog reda, vidi se da je prethodno uočeni padajući trend uklonjen. Proces sada zadovoljava uvjet stacionarnosti podataka te se može krenuti na analizu autokorelacije podataka.


### ➤ Autokorelacija podataka



Slika 6.15 Autokorelacija ACF/PACF (željezo)

Iz ACF i PACF sa [Slika 6.15] može se zaključiti da postoji autokorelacija među podacima te je potrebno provesti ARIMA modeliranje.

### ➤ ARIMA modeliranje

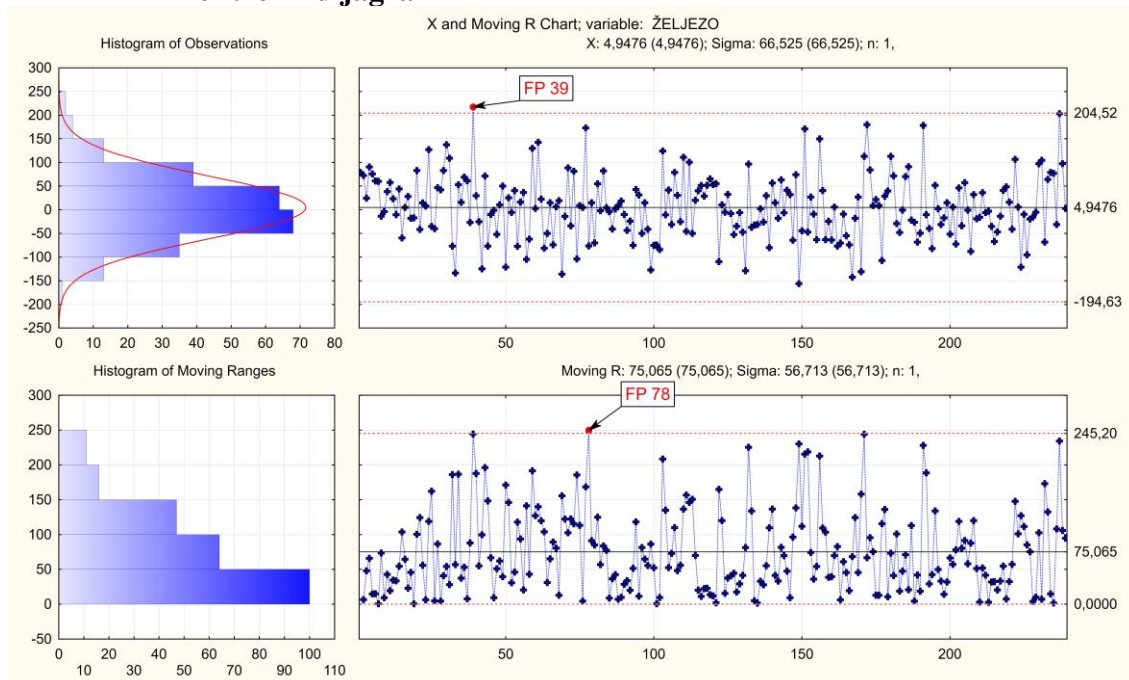


Slika 6.16 Korigirana autokorelacija ACF/PACF (željezo)

Nakon provedenog ARIMA modeliranja, autokorelacija je smanjena kako prikazuje [Slika 6.16]. Nakon ovog koraka dobiva se transformirani set podataka koji je adekvatan za primjenu X – MR kontrolnog dijagrama.

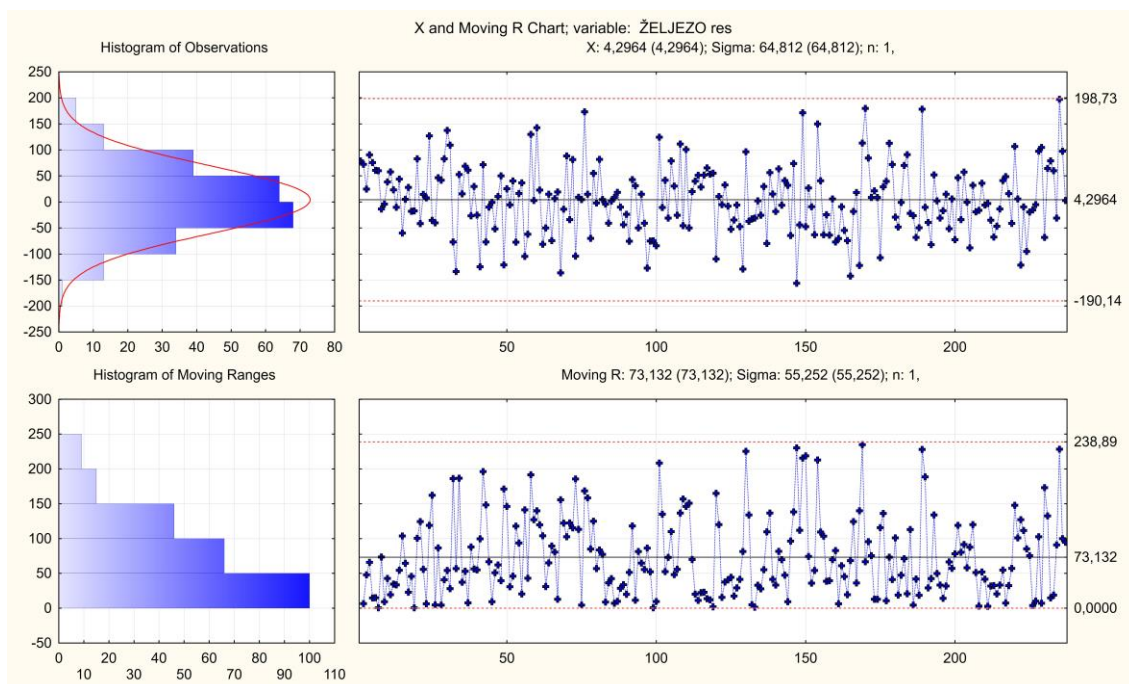


### ➤ X – MR kontrolni dijagram



Slika 6.17 X – MR kontrolni dijagram (željezo)

Promatranjem X – MR kontrolnog dijagrama može se uočiti da proces sadrži dvije točke izvan kontrolnih granica - točka 39 i točka 78. Sljedeći korak je uklanjanje te dvije točke te izrada novog kontrolnog dijagrama kako bi se ustanovile konačne kontrole granice koje će se koristiti za buduće promatranje procesa.



Slika 6.18 Korigirani X – MR kontrolni dijagram (željezo)


Nove kontrole granice iznose:

X KONTROLNI DIJAGRAM	MR KONTROLNI DIJAGRAM
UCL = 198,73	UCL = 238,89
LCL = - 190,14	LCL = 0

Ukoliko se u budućnosti pojavi vrijednost (nakon transformacije) koja prelazi ove kontrolne granice, to predstavlja indikaciju da se pojavio poseban uzrok koji potiče prekomjernu varijaciju te ga je potrebno pronaći i ukloniti. Bitno je naglasiti da proces ne proizvodi nužno loše proizvode kod ovakve pojave (u ovo slučaju bi to značilo vodu koja ne zadovoljava propisane zakonske vrijednosti), već da proces odstupa od uobičajenog rada.

### ➤ Sposobnost procesa

Nakon što je zadovoljen uvjet stabilnosti procesa, potrebno je provesti analizu sposobnosti procesa.



Slika 6.19 Sposobnost procesa (željezo)

Zakonom je propisana samo maksimalna dopuštena koncentracija željeza u vodi za piće koja prema prije navedenoj tablici iznosi 200 µg/l. Sposobnost procesa je, s obzirom na MDK vrijednost, odlična što se može vidjeti i s dijagrama na [Slika 6.19]. Demonstrirana sposobnost procesa iznosi 9,957 uzevši u obzir 6σ razinu kvalitete.



## 6.6. Arsen

U nastavku će biti prikazana primjena SPC metode na primjeru koncentracije arsena.

### ➤ Set podataka


**Tablica 6.7 Koncentracija arsena prije procesa obrade vode [µg/l]**

16 Siječanj	17 Veljača	18 Ožujak	19 Travanj	20 Svibanj	21 Lipanj	22 Srpanj	23 Kolovoz	24 Rujan	25 Listopad	26 Studenj	27 Prosinac
203,12	204,32	201,42	203,65	202,10	205,20	203,88	201,42	206,25	204,10	204,13	204,12
203,12	204,92	201,49	205,11	204,11	204,30	204,12	201,42	205,55	201,42	204,19	204,12
204,13	205,31	202,14	202,61	203,12	205,11	205,07	202,10	208,96	201,43	201,16	204,21
204,21	204,12	204,12	204,11	203,61	205,20	204,16	201,70	204,01	203,19	202,10	204,36
204,12	201,32	205,17	204,12	204,01	205,21	201,14	201,83	205,12	204,73	204,32	204,12
204,12	203,15	204,12	204,17	204,12	203,12	202,13	201,53	204,55	204,32	204,10	204,18
204,18	204,27	203,61	204,31	204,20	205,21	202,11	204,13	204,86	205,16	204,30	204,12
205,01	202,86	203,12	204,12	204,20	205,11	205,10	205,10	204,12	202,68	204,12	203,14
205,01	204,12	204,12	205,02	201,42	203,86	205,13	205,12	205,22	204,21	204,21	204,15
204,12	203,12	204,37	204,16	204,81	201,32	205,10	205,10	201,42	201,32	203,12	205,10
205,01	202,12	205,14	203,12	205,16	204,76	201,10	204,13	204,20	204,12	203,19	203,12
204,62	202,39	204,56	204,18	202,86	201,42	201,32	201,32	204,21	201,42	203,18	204,10
205,01	202,13	205,18	204,17	204,12	204,12	204,20	201,42	205,13	204,13	201,42	203,19
205,12	203,68	203,74	202,46	203,87	201,40	201,45	204,13	204,13	204,12	204,19	203,22
203,86	204,13	204,11	202,36	204,22	204,12	201,42	201,42	204,13	204,12	201,42	203,12
203,66	203,12	202,68	202,39	203,12	201,23	201,42	201,40	204,12	201,33	201,60	203,35
202,87	203,12	203,14	203,12	204,10	202,14	203,86	201,51	204,61	203,12	200,31	204,20
204,30	201,42	204,01	201,42	204,83	204,61	204,12	202,17	205,86	203,14	204,12	200,24
203,38	201,32	203,17	201,45	204,12	204,31	201,42	204,66	203,61	204,10	204,18	203,19
205,01	203,12	204,30	202,36	203,86	205,10	201,34	203,86	204,16	202,92	204,17	203,35

**Tablica 6.8 Koncentracija arsena nakon procesa obrade vode [µg/l]**

1 Siječanj	2 Veljača	3 Ožujak	4 Travanj	5 Svibanj	6 Lipanj	7 Srpanj	8 Kolovoz	9 Rujan	10 Listopad	11 Studenj	12 Prosinac
30,02	29,76	30,14	30,76	31,83	31,52	31,27	31,59	31,25	31,61	30,10	30,61
30,04	29,89	30,86	30,56	31,56	31,49	31,94	31,75	31,55	31,73	30,49	30,49
29,84	29,75	30,79	30,46	31,69	31,22	31,36	31,60	31,43	31,65	30,52	31,42
30,01	30,14	30,96	30,88	31,26	31,44	31,03	31,48	31,61	31,16	30,69	30,52
29,84	30,08	31,02	30,09	31,78	31,61	31,95	31,59	31,64	31,96	31,89	30,03
29,63	30,74	30,89	31,04	32,69	31,96	31,89	31,60	31,22	31,02	31,23	30,54
29,74	30,52	30,74	31,12	32,71	31,03	31,80	31,95	31,51	30,87	31,52	30,03
29,85	30,80	30,76	31,52	32,92	31,46	31,60	31,49	31,42	31,55	31,98	31,02
29,86	30,02	30,89	31,49	32,79	31,16	31,50	31,80	31,27	31,02	31,72	31,13
29,67	29,69	30,67	31,05	31,38	31,89	31,64	31,42	31,52	32,14	30,16	30,94
29,87	29,54	30,12	31,02	31,75	31,56	31,96	31,62	31,56	31,02	30,42	30,04
29,74	29,49	30,79	31,17	31,46	31,84	31,79	31,73	31,98	30,63	30,88	30,41
29,74	29,73	30,92	30,87	31,65	31,91	31,69	31,23	31,85	30,62	30,14	30,10
29,81	29,14	30,65	31,13	31,66	31,89	31,79	31,56	31,66	30,30	30,02	30,11
29,67	29,63	30,04	31,42	31,70	31,84	31,75	31,14	31,78	30,30	30,42	31,42
30,71	29,70	30,45	31,50	31,89	31,86	31,91	31,03	31,42	30,40	30,31	31,59
29,36	29,69	30,51	31,79	31,90	31,57	31,47	31,59	31,26	31,29	30,40	31,53
29,50	30,02	30,89	31,79	31,74	31,56	31,59	31,44	31,15	31,68	30,01	31,07
29,71	30,12	31,02	31,89	31,49	31,49	31,49	31,25	31,54	31,82	30,22	31,16
29,80	30,09	31,12	31,42	31,57	31,60	31,40	31,56	31,54	30,59	30,31	31,45

## ➤ Deskriptivna statistika



Slika 6.20 Numerička i grafička analiza (arsen)


Dijagrami sa [Slika 6.20] temelje se na podacima koji predstavljaju razliku koncentracije arsena u vodi prije i nakon provedbe tehnološkog procesa obrade, odnosno koncentraciju arsena koja se uklonila navedenim tretmanom. Iz njih se mogu iščitati osnovni parametri:

- srednja vrijednost: 172, 526  $\mu\text{g/l}$
- medijan: 172,737  $\mu\text{g/l}$
- mod: više vrijednosti (frekvencija: 3)
- standardna devijacija: 1,567  $\mu\text{g/l}$
- raspon: 8,905  $\mu\text{g/l}$

Iz P-P (eng. *Probability – Probability*) dijagrama može se zaključiti da podaci prate normalnu razdiobu, međutim ne tako glatko kao što je slučaj kod amonijaka i željeza. To je indikacija da postoji veće rasipanje vrijednosti (podataka). Upravo je zbog toga p vrijednost K – S testa granična s obzirom na odabranu razinu značajnosti.

- $(p > 0,05) > (\alpha = 0,05)$


### ➤ Stacionarnost procesa



**Slika 6.21 Stacionarnost procesa (arsen)**

U dijagramu na [Slika 6.21] prikazana je varijacija procesa po kvartalima. Može se uočiti da u procesu postoji značajna varijacija. Također, može se primijetiti da postoji trend opadanja koncentracije uklonjenog arsena tijekom vremena. Zaključak je da proces ne ispunjava uvjet stacionarnosti te da je potrebno provesti diferencijaciju prije ARIMA modeliranja.


### ➤ Diferencijacija podataka



**Slika 6.22 Diferencijacija podataka (arsen)**

Nakon diferencijacije prvog reda, vidi se da je prethodno uočeni padajući trend uklonjen. Proces sada zadovoljava uvjet stacionarnosti podataka te se može krenuti na analizu autokorelacije podataka.


### ➤ Autokorelacija podataka



Slika 6.23 Autokorelacija ACF/PACF (arsen)

Iz ACF i PACF sa [Slika 6.23] može se zaključiti da postoji autokorelacija među podacima te je potrebno provesti ARIMA modeliranje.


### ➤ ARIMA modeliranje



Slika 6.24 Korigirana autokorelacija ACF/PACF (arsen)

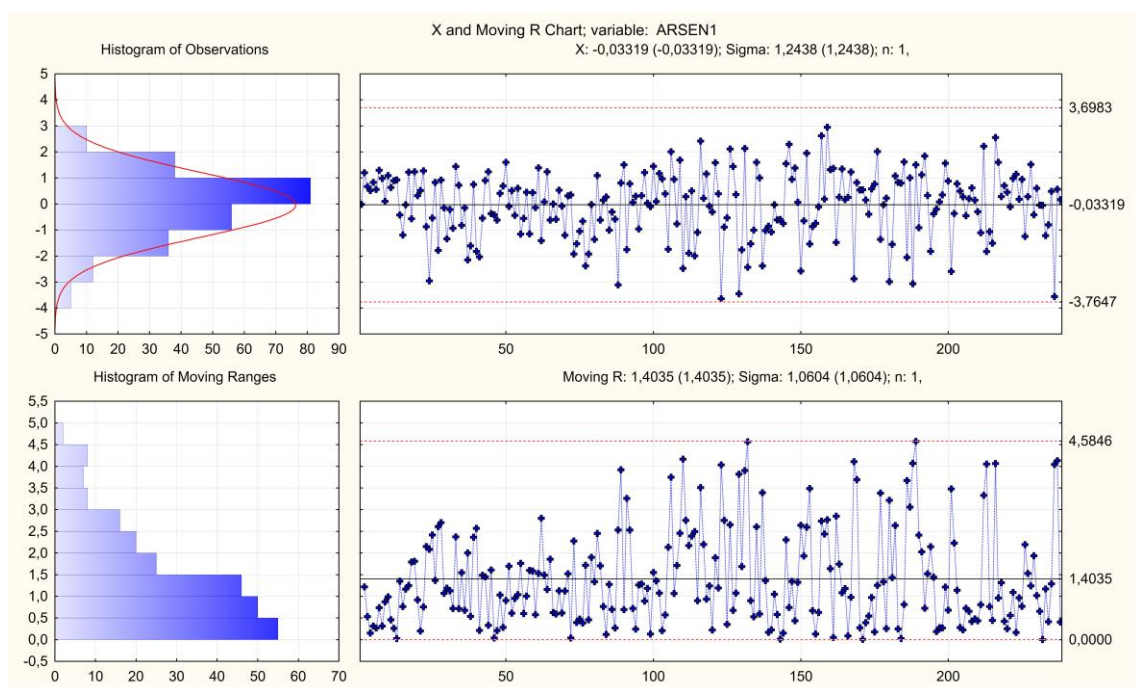
Nakon provedenog ARIMA modeliranja, autokorelacija je smanjena kako prikazuje [Slika 6.23]. Nakon ovog koraka dobiva se transformirani set podataka koji je adekvatan za primjenu X – MR kontrolnog dijagrama.

## ➤ X – MR kontrolni dijagram



Slika 6.25 X – MR kontrolni dijagram (arsen)

Promatranjem X – MR kontrolnog dijagrama može se uočiti da proces sadrži pet točaka izvan kontrolnih granica - točka 89, 124, 130, 162, 163. Sljedeći korak je uklanjanje tih točaka te izrada novog kontrolnog dijagrama kako bi se ustanovile konačne kontrole granice koje će se koristiti za buduće promatranje procesa.



Slika 6.26 Korigirani X – MR kontrolni dijagram (arsen)




Nove kontrole granice iznose:

X KONTROLNI DIJAGRAM	MR KONTROLNI DIJAGRAM
UCL = 3,6983	UCL = 4,5846
LCL = - 3,7647	LCL = 0

Ukoliko se u budućnosti pojavi vrijednost (nakon transformacije) koja prelazi ove kontrolne granice, to predstavlja indikaciju da se pojavio poseban uzrok koji potiče prekomjernu varijaciju te ga je potrebno pronaći i ukloniti. Bitno je naglasiti da proces ne proizvodi nužno loše proizvode kod ovakve pojave (u ovo slučaju bi to značilo vodu koja ne zadovoljava propisane zakonske vrijednosti), već da proces odstupa od uobičajenog rada.

#### ➤ Sposobnost procesa

Nakon što je zadovoljen uvjet stabilnosti procesa, potrebno je provesti analizu sposobnosti procesa.




**Slika 6.27 Sposobnost procesa (arsen)**

Zakonom je propisana samo maksimalna dopuštena koncentracija arsena u vodi za piće koja prema prije navedenoj tablici iznosi 50  $\mu\text{g/l}$ . Sposobnost procesa je, s obzirom na MDK vrijednost, odlična što se može vidjeti i s dijagrama na [Slika 6.27]. Demonstrirana sposobnost procesa iznosi 4,76 uzevši u obzir  $6\sigma$  razinu kvalitete.

## 6.7. Usporedba rezultata


Tehnološki proces obrade vode može se podijeliti na više manjih procesa koje je potrebno motriti zasebno kako bi se donijeli ispravni zaključci. U ovom slučaju odabrano je tri procesa, a to je uklanjanje amonijaka, željeza i arsena iz vode. Svaki od njih ima sebi svojstvene karakteristike koje će se u nastavku usporediti.

### ➤ Broj podataka izvan kontrolnih granica



Slika 6.28 Broj podataka izvan kontrolnih granica

### ➤ Demonstrirana sposobnost procesa



Slika 6.29 Demonstrirana sposobnost procesa

Iz grafikona na [Slika 6.28] može se jasno vidjeti da najveći broj podataka izvan kontrolnih granica posjeduje proces uklanjanja arsena. To je prvi znak da proces uklanjanja arsena ima najveću varijaciju tijekom promatranog vremena. Taj zaključak se mogao naslutiti uspoređujući grafove stacionarnosti među kojima je arsen imao najizraženiji trend. Uzevši u obzir promatrani period od 240 dana, ovih 5 podataka izvan kontrolnih granica čini svega 2%. Ono što je najbitnije, a može se iščitati iz  $\bar{X}$  – MR kontrolnog dijagrama na [Slika 6.25], da se nakon pojave podatka (mjerjenja) izvan kontrolnih granica pravovremeno postupalo te se poseban uzrok varijacije vrlo brzo uklonio. Što se tiče procesa uklanjanja željeza i amonijaka, može se zaključiti da su procesi vrlo stabilni sa svega dva podatka izvan kontrolnih granica. Iz grafikona na [Slika 6.29] vidljivo je, a sukladno broju podataka izvan kontrolnih granica, da proces uklanjanja arsena ima najmanju demonstriranu sposobnost između tri promatrana procesa. Bez obzira na to, svi procesi su iznimno sposobni i svi zadovoljavaju  $6\sigma$  razinu kvalitete što znači da su svi prikupljeni podaci (njih 240) unutar granica specifikacije koje su propisane zakonom.



## 7. UNAPREĐENJE PROCESA OBRADE (TRETIRANJA) VODE

Primjenom SPC metode na tehnološki postupak obrade vode, ustanovljeno je da proces funkcionira gotovo besprijeckorno. Međutim, i dalje postoji prostor za unapređenje istog. Unapređenje se može postići u dva područja:

- proces uklanjanja arsena
- iskorištenje prerađene tehnološke otpadne vode

### 7.1. Proces uklanjanja arsena

Novim zakonom od strane Europske unije propisana je maksimalno dopuštena koncentracija (MDK) arsena u vodi za ljudsku upotrebu u iznosu od 10 µg/l za razliku od prijašnje koja je iznosila 50 µg/l. Trenutno postrojenje (sustav) nije u mogućnosti postići traženu razinu te je potrebno unapređenje. Provedenom SPC metode također se detektirao problem arsena u vidu varijacije. Unapređenjem sustava postići će se novo-zakonska MDK razina, ali i ukloniti dosadašnja varijacija arsena.

### 7.2. Iskorištenje prerađene otpadne vode

Novim zakonom nastupio je i novi način naplaćivanja vode. Za razliku od starog gdje se naplaćivala voda koja je prerađena i isporučeno do krajnjeg korisnika, novim zakonom naplaćuje se ona količina vode koja je zahvaćena samim procesom obrade u koji je uključena i voda koja služi za ispiranje taložnika, precipitatora, akceleratora i filtera. Kako se ona vodi kao tehnološka otpadna voda koja se nakon određenog stupnja obrade vraća u okoliš, kao takva predstavlja veliki trošak. Unapređenjem sustava, ta voda koja se trenutno vraća u okoliš nakon određenog stupnja obrade, uz korekciju pH vrijednosti vraćat će se u sustav za obradu vode za ljudsku potrošnju te će se tako ukloniti trenutačni novčani gubici nastali novim zakonom.

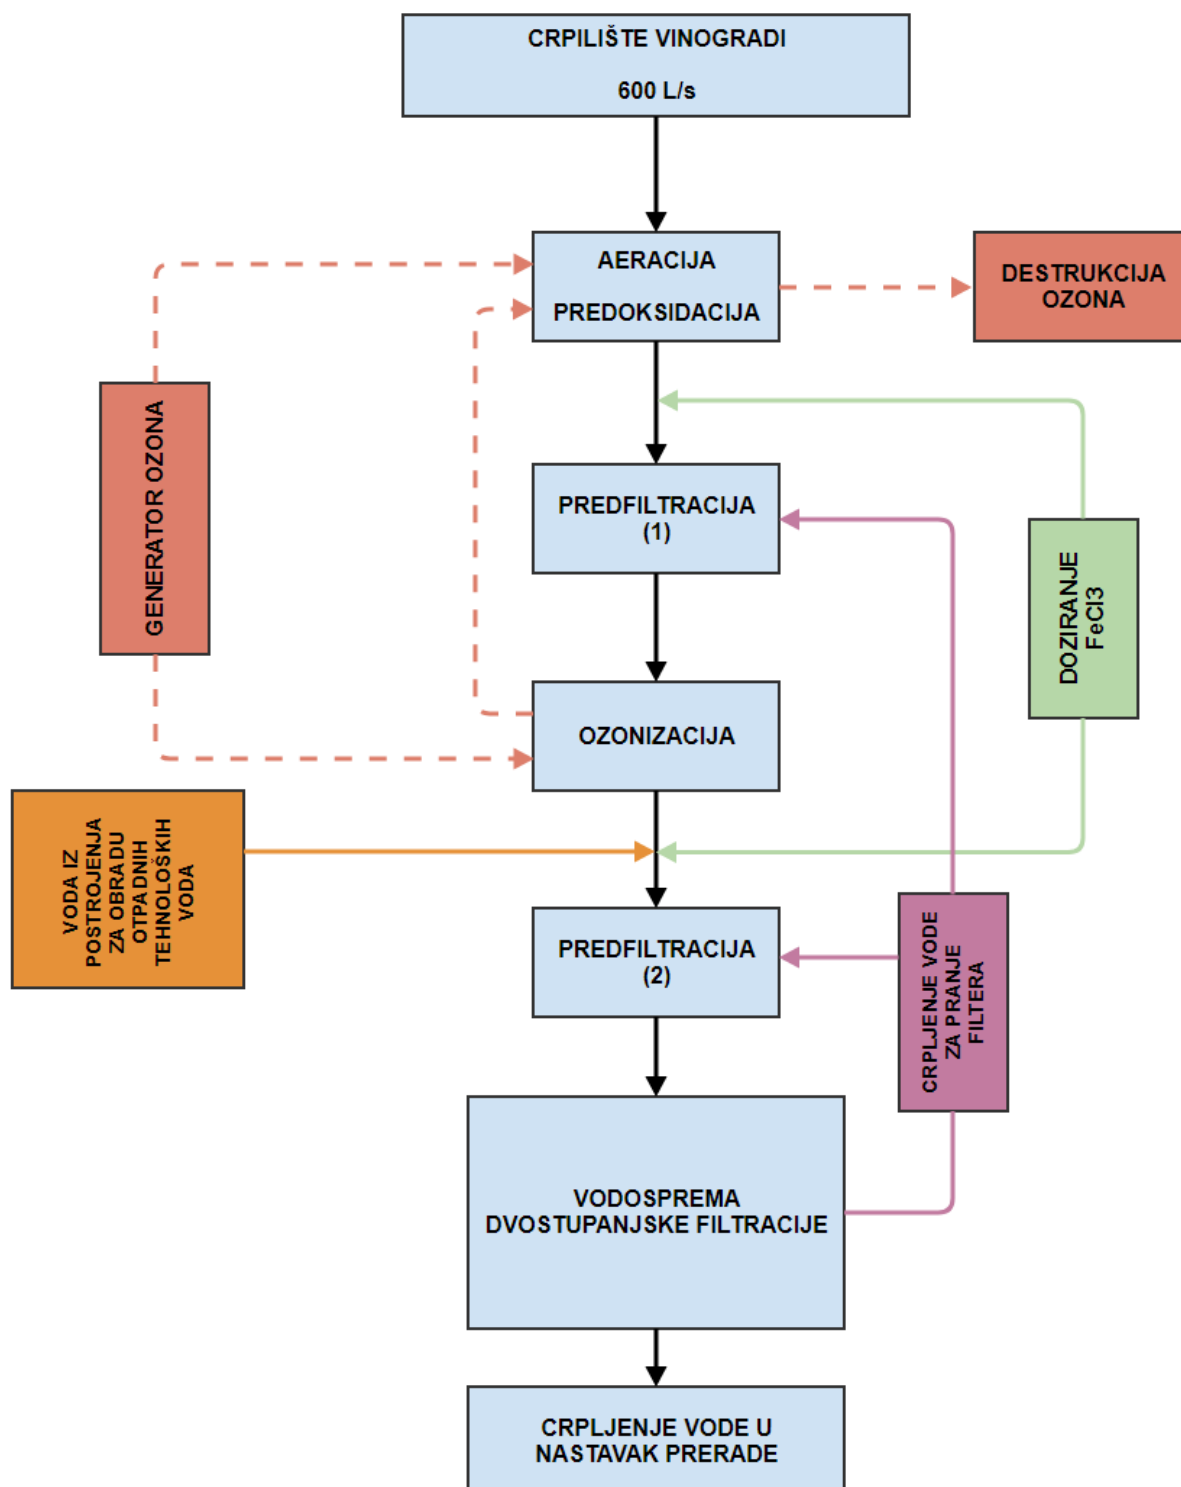
### 7.3. Sustav dvostupanjske filtracije

Novi tehnološki postupak uključivat će dvostupanjsku filtraciju kojom će se ukloniti prije navedeni nedostaci. Usporedba trenutnog i budućeg tehnološkog procesa prikazan je pomoću [Tablica 7.1].

**Tablica 7.1 Usporedba tehnoloških postupaka [14]**

Trenutni tehnološki proces		Novi tehnološki proces		
1	Aeriranje	1	Aeracija – predozonizacija	Dvostupanjska filtracija
2	Predoksidacija	2	Predfiltracija (1)	
3	Koagulacija	3	Ozonizacija	
4	Flokulacija	4	Predfiltracija (2) s prihvatom obrađenih otpadnih tehnoloških voda	
5	Taloženje	5	Skladištenje i crpljenje predobrađene vode	
6	Filtriranje i nitrifikacija	6	Koagulacija	
7	Dezinfekcija	7	Flokulacija	
8	Crpljenje u vodoopskrbnu mrežu	8	Taloženje	
		9	Filtracija i nitrifikacija	
		10	Dezinfekcija	
		11	Crpljenje u vodoopskrbnu mrežu	

#### 7.4. Funkcijska mapa toka vrijednosti dvostupanjske filtracije



Slika 7.1 Funkcijska mapa toka vrijednosti dvostupanjske filtracije

## 8. ZAKLJUČAK

Voda kao resurs predstavlja osnovnu životnu materiju i ima nemjerljiv značaj za živi svijet. Kako bi se postigla visoka kvaliteta pitke vode, tehnološki postupak obrade vode nameće se kao vrlo zanimljivo područje primjene statističke kontrole procesa. Kako bi se proces obrade vode bolje razumio, formirana je funkcijska mapa toka vrijednosti za realan slučaj.

Primjenom SPC metode na sustavu za obradu vode VODOVOD – OSIJEK, pratili su se procesi uklanjanja amonijaka, željeza i arsena iz sirove vode. Kako bi se ispravno provela metoda i donijeli ispravni zaključci, bilo je potrebno transformirati podatke koji su međusobno autokorelirali. Nakon transformacije podataka i primjene  $\bar{X}$  – MR kontrolnih dijagrama, definirale su se kontrolne granice za buduće praćenje procesa. Generalni zaključak je da tehnološki postupak obrade zadovoljava sve zakonske regulative i funkcionira besprijekorno. Određene varijacije unutar procesa mogu se pripisati sezonskim pojavama i nizu drugih faktora. Sposobnost procesa za uklanjanje amonijaka, željeza i arsena pokazuje da procesi zadovoljavaju  $6\sigma$  razinu kvalitete. Također, treba imati na umu da su se u sklopu ovog rada proučavali samo najznačajniji kemijski parametri karakteristični za podzemne vode. Ipak, za potpunu sliku o tehnološkom procesu obrade vode za ljudsku upotrebu, trebali bi se uključiti i drugi parametri.

Najveći problem u cijelom procesu predstavlja varijacija koncentracije arsena u vodi. Novim zakonom smanjena je maksimalna dopuštena koncentracija istog. Trenutno instalirani sustav nije u stanju postići traženu razinu te ga je potrebno unaprijediti. Rješenje je pronađeno u dvostupanjskoj filtraciji uz pomoć koje, ne samo da će se razina arsena spustiti ispod novo propisane razine, već će omogućiti i ponovnu upotrebu tehnoloških otpadnih voda.

Značajan doprinos u postizanju zadovoljavajuće razine kvalitete vode za ljudsku upotrebu može se postići kroz proučavanje i analizu tehnološkog procesa. Primjena SPC metode u ovom području svakako predstavlja korak prema boljoj, zdravijoj i uspješnijoj budućnosti.

## LITERATURA

- [1] Stapenhurst, T.: *Mastering Statistical Process Control*, 2005.
- [2] Oakland, J.: *Statistical process control*. Jordan Hill, Oxford, UK, 2008.
- [3] Qiu Peihua: *Statistical Process Control*, Chapman&Hall, USA, 2013.
- [4] Runje B.: Kontrola kvalitete (predavanja)
- [5] Prelec Z.: *Obrada otpadnih voda*, Rijeka, 2012.
- [6] Dobrović S., Ljubas D., Juretić H.: Ekološka zaštita (predavanja)
- [7] WaterTreatmentProcess, <http://watertreatmentprocess.net>  
(pristupljeno: veljača, 2018.)
- [8] AquaBlue: <http://aquabluechemical.com/help-with-industrial-water-treatment/>  
(pristupljeno: veljača, 2018.)
- [9] UNstats: <https://unstats.un.org/unsd/environment/wastewater.htm>  
(pristupljeno: veljača, 2018.)
- [10] Kondicioniranje vode, Grad Zagreb, 2012.  
[http://www.grad.unizg.hr/\\_download/repository/1.7.\\_Kondicioniranje\\_vode%5B1%5D.pdf](http://www.grad.unizg.hr/_download/repository/1.7._Kondicioniranje_vode%5B1%5D.pdf) (pristupljeno: veljača, 2018.)
- [11] European Commision: *Directive 2000/60/EC*
- [12] Republika Hrvatska: *Zakon o vodama (NN 56/2013)*
- [13] Republika Hrvatska: *Pravilnik o parametrima sukladnosti i metodama analize vode za ljudsku potrošnju (NN 125/2013)*
- [14] VODOVOD – OSIJEK d.o.o.: <https://vodovod.com/> (pistupljeno: veljača, 2018.)

### Napomena:

Za statističku obradu podataka korišten je programski paket *STATISTICA 13.3* (StatSoft)

## **PRILOZI**

### **I. CD-R disc**